

POLITECHNIKA CZĘSTOCHOWSKA
WYDZIAŁ ELEKTRYCZNY

Mgr inż. Grzegorz Dudek

Instytut Elektroenergetyki
Politechnika Częstochowska

Rozprawa doktorska

EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ
Z ZASTOSOWANIEM ALGORYTMÓW EWOLUCYJNYCH

TOM I

Promotor

Dr hab. inż. Władysław Brzozowski prof. P.Cz.

Praca wykonana częściowo w ramach projektu badawczego 8T10B03921
finansowanego przez KBN w latach 2001 – 2002

Częstochowa 2002

SPIS TREŚCI

TOM I

Oznaczenia i skróty	4
1. Wstęp	7
1.1. Cel i zakres pracy	8
1.2. Tezy rozprawy	9
1.3. Układ pracy	9
1.4. Twórcze elementy rozprawy	11
2. Wprowadzenie do zagadnień ekonomicznego rozdziału obciążeń i doboru składu jednostek wytwórczych	13
2.1. Ekonomiczny rozdział obciążeń czynnych metodą mnożników Lagrange'a [Gła99]	14
2.2. Ekonomiczny rozdział obciążeń czynnych metodą programowania dynamicznego	18
2.3. Dobór składu jednostek wytwórczych metodą charakterystyk czasów granicznych	21
3. Przegląd literatury i stanu badań w zakresie ekonomicznego rozdziału obciążeń i doboru składu jednostek wytwórczych	25
3.1. Ekonomiczny rozdział obciążeń z wykorzystaniem konwencjonalnych metod optymalizacji	26
3.2. Ekonomiczny rozdział obciążeń z wykorzystaniem metod sztucznej inteligencji	30
3.3. Ekonomiczny rozdział obciążeń z uwzględnieniem wymagań ochrony środowiska naturalnego	36
3.4. Dobór składu jednostek wytwórczych	38
4. Ekonomiczny rozdział obciążeń na poziomie elektrowni	51
4.1. Sformułowanie zadania. Funkcja kosztu. Ograniczenia	51
4.2. Metodyki rozwiązania zadania ekonomicznego rozdziału obciążeń	54
4.3. Charakterystyki kosztów zmiennych i kosztów rozruchów bloków energetycznych	57
4.3.1. Koszty paliwa i materiałów pomocniczych	57
4.3.2. Koszty użytkowania środowiska naturalnego	60
4.3.3. Konstrukcja charakterystyk kosztów zmiennych	66
4.3.4. Konstrukcja charakterystyk kosztów rozruchów	72
4.4. Modele optymalizacyjne do ekonomicznego rozdziału obciążeń na poziomie elektrowni – podejście kombinowane	79
4.4.1. Algorytmy ewolucyjne	80
4.4.1.1. Algorytm z binarną reprezentacją stanów pracy jednostek	80
4.4.1.1.1. Reprezentacja zmiennych RB1	80
4.4.1.1.2. Operatory ewolucyjne i genetyczne	80

4.4.1.1.3. Metody eliminacji ograniczeń funkcji kosztu.....	91
4.4.1.2. Algorytm z binarną reprezentacją momentów odstawień i załączeń....	96
4.4.1.2.1. Reprezentacja zmiennych RB2	96
4.4.1.2.2. Operatory. Metody eliminacji ograniczeń funkcji kosztu.....	99
4.4.1.3. Algorytm z całkowitoliczbową reprezentacją momentów odstawień i załączeń.....	100
4.4.1.3.1. Reprezentacja zmiennych RC	100
4.4.1.3.2. Operatory. Metody eliminacji ograniczeń funkcji kosztu.....	100
4.4.1.4. Schemat algorytmu optymalizacyjnego	104
4.4.2. Algorytmy symulowanego wyżarzania	107
4.4.2.1. Schematy wyżarzania.....	108
4.4.2.2. Schemat algorytmu optymalizacyjnego	114
4.4.3. Algorytm hybrydowy symulowanego wyżarzania i algorytmu ewolucyjnego	116
4.4.4. Obliczenia optymalizacyjne ekonomicznego rozdziału obciążeń na poziomie elektrowni – podejście kombinowane.....	121
4.4.4.1. Wyniki.....	125
4.5. Modele optymalizacyjne do ekonomicznego rozdziału obciążeń na poziomie elektrowni – podejście zintegrowane	142
4.5.1. Kompleksowy algorytm ewolucyjny KAE.....	142
4.5.1.1. Reprezentacja zmiennych	142
4.5.1.2. Operatory genetyczne	143
4.5.1.3. Metody eliminacji ograniczeń funkcji kosztu.....	145
4.5.1.4. Schemat algorytmu optymalizacyjnego	149
4.5.2. Sekwencyjny algorytm ewolucyjny SAE	151
4.5.2.1. Reprezentacja zmiennych	152
4.5.2.2. Operatory. Metody eliminacji ograniczeń funkcji kosztu.....	153
4.5.2.3. Schemat algorytmu optymalizacyjnego	153
4.5.3. Obliczenia optymalizacyjne ekonomicznego rozdziału obciążeń na poziomie elektrowni – podejście zintegrowane	155
4.6. Analiza dokładności proponowanych modeli optymalizacyjnych.....	162
5. Ekonomiczny rozdział obciążeń na poziomie systemu elektroenergetycznego	180
5.1. Sformułowanie zadania. Funkcja kosztu. Ograniczenia	180
5.2. Modele optymalizacyjne do ekonomicznego rozdziału obciążeń na poziomie systemu elektroenergetycznego	181
6. Wnioski końcowe	184
Spis tablic.....	186
Spis rysunków.....	187
Literatura.....	189

TOM II

Dodatek 1.	Charakterystyki i właściwości eksploatacyjne bloków energetycznych.....	2
D1.1.	Charakterystyki energetyczne	2
D1.2.	Wpływ warunków pracy na charakterystyki energetyczne.....	5
D1.3.	Elastyczność ruchowa bloków energetycznych.....	10
D1.4.	Charakterystyki strat rozruchowych	13
Dodatek 2.	Metodyka optymalizacji za pomocą algorytmów ewolucyjnych i symulowanego wyżarzania	18
Dodatek 3.	Dane wejściowe	26
Dodatek 4.	Uwagi odnośnie konstrukcji charakterystyk kosztowych bloków energetycznych Elektrowni Bełchatów	31
Dodatek 5.	Zestawienie charakterystyk kosztów zmiennych oraz kosztów rozruchów bloków energetycznych w formie tabelarycznej	34
Dodatek 6.	Rezultaty obliczeń optymalizacyjnych dla uproszczonego zadania ERO-k na poziomie elektrowni	45
Dodatek 7.	Obliczenia rozplywu mocy w systemie elektroenergetycznym [Kre96]	50
Dodatek 8.	Zestawienie kodów źródłowych programów komputerowych	54
D8.1.	Program do ekonomicznego rozdziału obciążeń na poziomie elektrowni z zastosowaniem algorytmów ewolucyjnych – podejście kombinowane	55
D8.2.	Program do ekonomicznego rozdziału obciążeń na poziomie elektrowni z zastosowaniem algorytmu symulowanego wyżarzania – podejście kombinowane	73
D8.3.	Program do ekonomicznego rozdziału obciążeń na poziomie elektrowni z zastosowaniem algorytmu hybrydowego SW+AE – podejście kombinowane	78
D8.4.	Program do ekonomicznego rozdziału obciążeń na poziomie elektrowni z zastosowaniem kompleksowego algorytmu ewolucyjnego KAE	83
D8.5.	Program do ekonomicznego rozdziału obciążeń na poziomie elektrowni z zastosowaniem sekwencyjnego algorytmu ewolucyjnego SAE	90
D8.6.	Wybrane programy pomocnicze	95

OZNACZENIA I SKRÓTY

Wykaz ważniejszych oznaczeń

$\alpha_i(t)$	- zmienna binarna przyjmująca wartość 1 gdy blok i -ty pracuje w chwili t lub 0, gdy blok znajduje się w rezerwie w chwili t ,
δ	- błąd,
ε_k	- przyrost względny kosztów zmiennych w zł/(MW·h),
η	- sprawność, skuteczność,
σ	- odchylenie standardowe,
σ_{opt}	- odchylenie standardowe liczby odwołań l_{opt} do funkcji kosztu w algorytmie optymalizacyjnym, potrzebnej do znalezienia optimum,
ΔP_s	- straty mocy czynnej w systemie (w sieci przesyłowej),
Δt	- krok dyskretyzacji czasu w h,
B	- strumień zużycia paliwa w Mg/h,
ch	- chromosom, genotyp,
c_j	- cena jednostkowa,
c_{opt}	- częstość znalezienia najlepszego rozwiązania,
E	- emisja substancji zanieczyszczających w kg/h,
$F_P, \bar{F}_P, F_{Pmin}, F_{Pmax}$	- funkcja kosztu, jej wartość średnia, minimalna i maksymalna,
K_c	- suma kosztów zmiennych i kosztów rozruchów jednostek wytwórczych,
K_{ez}	- koszt emisji zanieczyszczeń w zł lub strumień kosztu emisji zanieczyszczeń w zł/h,
k_j	- jednostkowy koszt zmienny wytwarzania w zł/(MW·h),
K_r	- koszt rozruchu jednostki wytwórczej w zł,
K_z	- strumień kosztu zmiennego wytwarzania energii elektrycznej w zł/h lub koszt zmienny wytwarzania w zł,
L_{gen}, l_{gen}	- liczba i licznik generacji algorytmu ewolucyjnego,
l_{opt}	- liczba odwołań do funkcji kosztu w algorytmie optymalizacyjnym, potrzebna do znalezienia optimum,
l_{pc}	- liczba punktów cięcia chromosomu podczas krzyżowania wielopunktowego,
L_{pop}	- liczebność populacji,
L_{pw}	- liczba iteracji w pętli wewnętrznej algorytmu symulowanego wyżarzania,
L_{pz}	- liczba iteracji w pętli zewnętrznej algorytmu symulowanego wyżarzania (liczba poziomów temperaturowych),
N	- liczba dyspozycyjnych jednostek wytwórczych,
\mathcal{P}	- populacja, zbiór chromosomów,
p_a	- prawdopodobieństwo akceptacji rozwiązania próbnego w symulowanym wyżarzaniu,
p_k	- prawdopodobieństwo krzyżowania,

P_{ni}	- moc czynna netto generowana przez i -tą jednostkę w MW,
P_{nmaxi}	- moc czynna osiągalna netto i -tej jednostki w MW,
P_{nmini}	- minimum techniczne netto i -tej jednostki w MW,
P_{nopt}	- najlepsze rozwiązanie (obciążenia jednostek netto w MW), znalezione przez testowane modele optymalizacyjne,
P_{rw}	- moc rezerwy wirującej w MW,
p_w	- prawdopodobieństwo wymiany chromosomu na naprawioną wersję,
P_z	- moc zapotrzebowana w MW,
Q_d	- strumień energii chemicznej doprowadzonej do kotła w paliwie w GJ/h,
r_b	- binarna liczba losowa, $r_b = \{0, 1\}$,
r_c	- liczba całkowita losowana z rozkładu jednostajnego,
round(.)	- operator zaokrąglania do najbliższej liczby całkowitej,
r_r	- liczba rzeczywista losowana z rozkładu jednostajnego,
r_t	- rozmiar turnieju w selekcji turniejowej,
r_T	- współczynnik redukcji temperatury w strategii Kirkpatricka,
t	- numer przedziału czasowego, $t = 1, 2, \dots, T$,
T	- okres optymalizacji w h lub temperatura (parametr kontrolno – sterujący algorytmu SW),
t_{opt}	- czas działania algorytmu potrzebny do znalezienia optimum,
t_p	- czas postoju bloku w rezerwie w h,
t_{ps}	- zmienna określająca stan początkowy jednostki wytwórczej, tj. liczbę godzin postoju jednostki w rezerwie lub pracy przed pierwszą godziną okresu optymalizacji w h,
t_r	- czas pracy bloku po rozruchu w h,
W	- wartość opałowa paliwa w kJ/kg,
w_a, w_b, w_c, w_d	- współczynniki wielomianu aproksymującego charakterystykę kosztów zmiennych bloku,
w_e, w_f, w_g, w_h	- parametry funkcji aproksymującej charakterystykę kosztów rozruchu bloku,
w_j	- współczynnik jednorodności w krzyżowaniu jednorodnym,
w_m	- oczekiwana liczba mutacji chromosomu,
w_t	- oczekiwana liczba transpozycji chromosomu,
w_u	- wskaźnik unosu,
w_z	- wskaźnik zużycia.

Wykaz skrótów

AE	- algorytm ewolucyjny,
AG	- algorytm genetyczny,
ARCM	- automatyczna regulacja częstotliwości i mocy czynnej,
DSJW	- dobór składu jednostek wytwórczych,
ERO	- ekonomiczny rozdział obciążeń,
ERO-k	- ekonomiczny rozdział obciążeń - podejście kombinowane,
ERO-z	- ekonomiczny rozdział obciążeń - podejście zintegrowane,
IOS	- instalacja odsiarczania spalin,
JW	- jednostka wytwórcza, blok energetyczny,
K1P	- krzyżowanie jednopunktowe,
KAE	- kompleksowy algorytm ewolucyjny,
KCA	- krzyżowanie arytmetyczne w wersji całkowitoliczbowej,
KCH	- krzyżowanie heurystyczne w wersji całkowitoliczbowej,
KCJ	- krzyżowanie jednorodne w wersji całkowitoliczbowej,
KDM	- Krajowa Dyspozycja Mocy,
KJR	- krzyżowanie jednorodne,
KWP	- krzyżowanie wielopunktowe,
MB1	- mutacja binarna zależna od liczby jednostek niezbędnych do pokrycia zapotrzebowania,
MB2	- mutacja binarna „przesunięć momentów rozruchów i odstawień”,
MB3	- mutacja binarna zależna od liczby bloków potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek,
MBR	- mutacja binarna równomierna,
MCN	- mutacja całkowitoliczbowa nierównomierna,
MCR	- mutacja całkowitoliczbowa równomierna,
OT	- operator transpozycji,
RB1	- reprezentacja binarna stanów pracy jednostek,
RB2	- reprezentacja binarna momentów załączeń i odstawień,
RC	- reprezentacja całkowitoliczbowa momentów załączeń i odstawień,
SAE	- sekwencyjny algorytm ewolucyjny,
SEE	- system elektroenergetyczny,
SFK	- strategia z funkcją kary,
SND	- deterministyczna strategia naprawy osobników niedopuszczalnych,
SNL	- losowa strategia naprawy osobników niedopuszczalnych,
SW	- symulowane wyżarzanie,
SW+AE	- algorytm hybrydowy symulowanego wyżarzania i algorytmu ewolucyjnego,
TKE	- techniczno - ekonomiczna kontrola pracy elektrowni.

1. WSTĘP

Planowanie pracy systemu elektroenergetycznego (SEE) ma na celu przygotowanie do ruchu optymalnych układów pracy systemu, zapewniających ciągłość dostawy energii o wymaganej jakości przy jak najmniejszych kosztach, do których zalicza się: koszt wytwarzania (głównie paliwa), koszt przesyłu i rozdziału oraz koszt niezawodnej dostawy. W planowaniu pracy SEE formułuje się zadanie optymalizacyjne, polegające na minimalizacji kosztów zmiennych w określonym przedziale czasu. Na koszty te wpływają [Por96]:

- dobór składu bloków niezbędnych do pokrycia zapotrzebowania,
- rozdział mocy czynnej na poszczególne bloki elektrowni ciepłych,
- gospodarka wodą w elektrowniach wodnych zbiornikowych i pompowych,
- czynniki towarzyszące pracy sieci, a mianowicie straty i ograniczenia, które powodują zmiany w produkcji energii,
- zmiany ilości energii wymienianej z sąsiednimi systemami.

Z racji rozległości problemu i bardzo dużej liczby narzuconych warunków ograniczających (warunki bilansów mocy, ograniczenia techniczne systemowe i elektrowniane), zadanie to jest trudne do rozwiązania i dekomponuje się je na prostsze zadania suboptymalizacyjne. Źródłem największych oszczędności jest optymalizacja doboru składu jednostek wytwórczych (DSJW) oraz ekonomiczny rozdział obciążeń czynnych (ERO) na jednostki [Ber86a]. Jak wykazały przeprowadzone w latach sześćdziesiątych analizy, stosując DSJW i ERO dla krajowego SEE, uzyskuje się oszczędności w granicach 0,5% kosztów produkcji [Gła99].

ERO stanowi problem programowania nieliniowego, który najczęściej rozwiązuje się metodą mnożników Lagrange'a. Rozwiązanie zwane jest ERO według równych przyrostów względnych kosztów zmiennych. Metoda ta stosowana jest w kraju począwszy od pierwszej połowy lat sześćdziesiątych do celów bieżącego planowania i prowadzenia ruchu [Gła99]. W rozwiązaniu ERO metodą równych przyrostów względnych kosztów zmiennych, wymaga się ciągłych, różniczkowalnych i wypukłych charakterystyk kosztowych jednostek wytwórczych (JW), co zwykle nie jest zachowane. Ponadto metoda ta pozwala na przeprowadzenie jedynie optymalizacji chwilowych (tzw. ERO „w punkcie”) nie uwzględniając kosztów rozruchów jednostek, a rozwiązanie jest zależne od zbioru branych pod uwagę w obliczeniach JW. Optymalizacja tego zbioru realizowana jest przez odrębne metody DSJW. Uwzględnienie warunków ograniczających narzuconych na rozwiązania, w klasycznej metodzie ERO według równych przyrostów względnych, jest kłopotliwe.

Dobór składu jednostek wytwórczych jest problemem optymalizacji kombinatorycznej, polegającym na wyznaczeniu czasów wyłączeń i załączeń współpracujących bloków energetycznych w zadanym okresie czasu. Rozwiązanie zależne jest od rozdziału prognozowanego zapotrzebowania na załączone bloki. Do DSJW, dla potrzeb Krajowej Dyspozycji Mocy (KDM), opracowano metodę charakterystyk czasów granicznych (autorstwa M. Toronia [Tor62]), która była stosowana w praktyce ponad 30 lat. Metoda charakterystyk czasów granicznych jest metodą uproszczoną, nie uwzględniającą

zmienności strumienia zysków z odstawień lub załączeń jednostek. Ponadto, wobec przyjętych w niej założeń upraszczających, można ją stosować na poziomie większych SEE, w których odstawienie bądź załączenie jednostki nie spowoduje zmiany przyrostu względnego kosztu zmiennego. Obserwowana w ostatnich latach tendencja do instalowania regulatorów grupowych w elektrowniach (Elektrownia Bełchatów, Elektrownia im. T. Kościuszki w Połańcu), skłania do opracowania metod DSJW i ERO dla pojedynczych elektrowni.

W niniejszej rozprawie doktorskiej proponuje się metody optymalizacji globalnej: algorytmy ewolucyjne (AE) i symulowane wyżarzanie (SW), do zadania ekonomicznego rozdziału obciążeń czynnych na współpracujące jednostki wytwórcze. Zadanie obejmuje dobór składu jednostek, jak i rozdział obciążeń na jednostki. Metody optymalizacji wykorzystujące AE pozbawione są wielu wad metod klasycznych – nie stawiają ograniczeń co do matematycznej postaci charakterystyk kosztowych bloków (nie wymaga się postaci analitycznej tych charakterystyk, a osobliwości pochodnych są nieistotne), pozwalają dowolnie kształtować funkcję kosztu (może ona obejmować koszty ochrony środowiska, rozruchów, strat sieciowych itp.), a także uwzględniać ograniczenia. ERO metodą równych przyrostów względnych kosztów zmiennych, bez wcześniejszej optymalizacji doboru składu jednostek, daje rozwiązania dalekie od optymalnych, podczas gdy AE pozwala znaleźć jednocześnie optymalną kombinację JW oraz optymalne ich obciążenia.

Opracowane w rozprawie metodyki ERO są przydatne głównie dla potrzeb pojedynczych elektrowni i systemów elektroenergetycznych sterowanych centralnie, gdzie dobór składu jednostek wytwórczych i ekonomiczny rozdział obciążeń jest przeprowadzany codziennie. Po ustaleniu warunków funkcjonowania energetyki krajowej, która obecnie jest w stanie przejściowym [Pop99], [Gła96], [Jan96] oraz po sprecyzowaniu kryteriów optymalizacji SEE w warunkach hurtowego rynku energii elektrycznej (REE) [Boj99], zaproponowane metodyki mogą być przydatne w przyszłości do zadań optymalizacji pracy systemu elektroenergetycznego w warunkach rynkowych. Proponowane algorytmy mogą być użyteczne szczególnie w rynkowych zdecentralizowanych modelach funkcjonowania SEE (np. w tzw. „modelu kalifornijskim”), w których na wytwórcy spoczywa obowiązek i odpowiedzialność w zakresie indywidualnego planowania pracy jednostek wytwórczych (*unit self-commitment*) [Toc99]. Wg [Jur99] realizowany aktualnie w KSE model REE zmierza w kierunku „modelu kalifornijskiego”.

1.1. CEL I ZAKRES PRACY

Celem pracy jest opracowanie, a następnie analiza metod optymalizacji, wykorzystujących algorytmy ewolucyjne i symulowane wyżarzanie, do optymalnego rozdziału obciążeń na energetyczne jednostki wytwórcze (bloki energetyczne elektrowni cieplnych). Proponowane algorytmy optymalizacyjne rozwiązują równocześnie dwa problemy:

- dobór składu jednostek niezbędnych do pokrycia zapotrzebowania oraz
- rozdział mocy czynnej na poszczególne jednostki,

w taki sposób, aby zminimalizować koszty wytwarzania energii elektrycznej w zadanym okresie czasu. Algorytmy zostały opracowane i analizowane głównie dla zadań optymalizacji rozdziału obciążeń na poziomie pojedynczych elektrowni, ale zaproponowano też ich zmodyfikowane wersje dla zadań ERO na poziomie całego SEE.

W zakres pracy wchodzi:

1. Opracowanie metodyki konstrukcji charakterystyk kosztów zmiennych bloków energetycznych na bazie charakterystyk energetycznych.
2. Opracowanie metodyki konstrukcji charakterystyk kosztów rozruchów bloków energetycznych na bazie charakterystyk strat rozruchowych.
3. Opracowanie modeli optymalizacyjnych do ekonomicznego rozdziału obciążeń na poziomie elektrowni z wykorzystaniem algorytmów ewolucyjnych.
4. Opracowanie modeli optymalizacyjnych do ekonomicznego rozdziału obciążeń na poziomie elektrowni z wykorzystaniem algorytmów symulowanego wyżarzania.
5. Opracowanie modeli optymalizacyjnych do ekonomicznego rozdziału obciążeń na poziomie elektrowni z wykorzystaniem algorytmu hybrydowego SW i AE.
6. Opracowanie programów komputerowych implementujących proponowane modele optymalizacyjne oraz programów pomocniczych.
7. Przykładowe obliczenia optymalizacyjne ERO na poziomie elektrowni z zastosowaniem proponowanych algorytmów.
8. Analiza dokładności proponowanych modeli optymalizacyjnych.
9. Opracowanie metodyki ekonomicznego rozdziału obciążeń na poziomie systemu elektroenergetycznego z wykorzystaniem proponowanych modeli optymalizacyjnych.

1.2. TEZY ROZPRAWY

W oparciu o analizę metod optymalizacyjnych bazujących na algorytmach ewolucyjnych, algorytmach symulowanego wyżarzania i algorytmach klasycznych, na podstawie przeglądu literatury przedmiotowej oraz badań wstępnych przeprowadzonych przez autora rozprawy, sformułowano następujące tezy:

1. Za pomocą technik optymalizacji wykorzystujących metody ewolucyjne można dokonać ekonomicznego rozdziału obciążeń czynnych oraz doboru składu współpracujących jednostek wytwórczych.
2. Algorytmy ewolucyjne pozwalają uzyskać lepsze wyniki od metod klasycznych, tj. ERO metodą przyrostów względnych kosztów zmiennych i doboru składu jednostek wytwórczych metodą charakterystyk czasów granicznych oraz ERO metodą programowania dynamicznego.

1.3. UKŁAD PRACY

Rozdział 2 rozprawy stanowi wprowadzenie do zagadnienia ekonomicznego rozdziału obciążeń i doboru składu jednostek wytwórczych. Opisano klasyczne metody rozwiązania tych problemów: ERO metodą równych przyrostów względnych kosztów zmiennych, DSJW metodą charakterystyk czasów granicznych oraz ERO metodą programowania dynamicznego.

Przegląd literatury w zakresie metod optymalizacyjnych stosowanych do ERO i DSJW zamieszczono w rozdziale 3.

W rozdziale 4 przedstawiono metody konstrukcji charakterystyk kosztów zmiennych i kosztów rozruchów JW, zaproponowano i analizowano modele optymalizacyjne do ekonomicznego rozdziału obciążeń na poziomie elektrowni.

Rozdział 5 zawiera problematykę ekonomicznego rozdziału obciążeń na poziomie systemu elektroenergetycznego. Podano sposoby modyfikacji algorytmów optymalizacyjnych prezentowanych w rozdziale 4, tak aby przystosować je do zadania ERO na poziomie SEE z uwzględnieniem strat mocy.

Wnioski końcowe pracy zamieszczono w rozdziale 6.

W dodatku 1 opisano charakterystyki energetyczne podstawowych urządzeń elektrowni i bloków energetycznych oraz czynniki eksploatacyjne wpływające na ich kształt. Zaprezentowano metody uwzględnienia wpływu tych czynników na charakterystyki energetyczne: metodę techniczno – ekonomicznej kontroli pracy elektrowni (TKE), metodę aproksymacji statystycznej oraz propozycje modeli aproksymacyjnych opartych na sieciach neuronowych. Poruszono tematykę elastyczności ruchowej bloków energetycznych. Przedstawiono sposoby określania strat energii w trakcie rozruchu, czynniki wpływające na te straty oraz wzory aproksymujące straty rozruchowe.

Schematy AE i SW oraz podstawowe problemy związane z ich projektowaniem i zastosowaniem do zadań optymalizacyjnych opisano w dodatku 2. W dodatku 3 zestawiono dane wejściowe do obliczeń optymalizacyjnych. W dodatku 4 zamieszczono uwagi dotyczące konstrukcji charakterystyk kosztowych bloków energetycznych Elektrowni Bełchatów. W dodatku 5 zestawiono w formie tabelarycznej skonstruowane w pracy charakterystyki kosztowe bloków energetycznych 360 MW Elektrowni Bełchatów. Rezultaty obliczeń optymalizacyjnych ERO dla zadania uproszczonego przedstawiono w dodatku 6. W dodatku 7 opisano zagadnienie rozplywu mocy w systemie elektroenergetycznym. Kody źródłowe programów komputerowych implementujących zaprojektowane algorytmy optymalizacyjne i kody wybranych programów pomocniczych zamieszczono w dodatku 8.

Rozdziały 2 i 3, dodatek 1, 2 i 7 powstały głównie na podstawie badań literatury tematycznej, rozdziały 4 i 5 zawierają treści merytoryczne – pomysły, opis badań i analizy przeprowadzone przez autora rozprawy. Poniżej omówiono bardziej szczegółowo zawartość rozdziału 4.

W podrozdziale 4.3 opisano sposoby konstrukcji charakterystyk kosztów zmiennych oraz kosztów rozruchów bloków energetycznych. W charakterystykach tych uwzględniono, oprócz kosztów paliwa i materiałów eksploatacyjnych, koszty związane z gospodarczym wykorzystaniem środowiska naturalnego. Skonstruowano charakterystyki kosztowe wykorzystując dane rzeczywiste otrzymane z Elektrowni Bełchatów i KDM.

Podrozdział 4.4.1 obejmuje bazujące na AE modele optymalizacyjne do ERO na poziomie elektrowni w wersji kombinowanej. Zdefiniowano AE z reprezentacją binarną stanów pracy JW, z reprezentacją całkowitoliczbową oraz binarną czasów odstawień i załączeń JW. Szczegółowo opisano specjalizowane operatory genetyczne dostosowane do reprezentacji zmiennych. Przedstawiono metody eliminacji ograniczeń funkcji kosztu.

W podrozdziale 4.4.2 zaprezentowano algorytmy SW do ERO na poziomie elektrowni w wersji kombinowanej. Opisano strategie schładzania: statyczną Kirkpatricka i adaptacyjną Aartsa.

W podrozdziale 4.4.3 wprowadzono algorytm hybrydowy SW i AE do zadania ERO na poziomie elektrowni w wersji kombinowanej. Opisano strategie rekombinacji zdefiniowane dla tego algorytmu: losową, wg kryterium odległościowego, z najlepszym punktem i mikrowyżarzania.

Wyniki obliczeń ERO na poziomie elektrowni w wersji kombinowanej, z wykorzystaniem proponowanych modeli optymalizacyjnych, przedstawiono i zanalizowano w podrozdziale 4.4.4. Obliczenia wykonano na skonstruowanych wcześniej dla Elektrowni Belchatów charakterystykach kosztowych. Przedstawiono też wyniki obliczeń optymalizacyjnych przeprowadzonych z wykorzystaniem algorytmu z twardą selekcją, algorytmu Monte Carlo oraz algorytmu charakterystyk czasów granicznych.

W podrozdziale 4.5.1 przedstawiono definicję kompleksowego, a w podrozdziale 4.5.2 – sekwencyjnego AE do ERO na poziomie elektrowni w wersji zintegrowanej. Opisano reprezentacje zmiennych, operatory genetyczne i metody eliminacji ograniczeń funkcji kosztu.

Eksperymenty numeryczne ERO na poziomie elektrowni w wersji zintegrowanej z wykorzystaniem kompleksowego i sekwencyjnego AE opisano w podrozdziale 4.5.3.

W podrozdziale 4.6 zamieszczono analizę dokładności proponowanych modeli optymalizacyjnych. Za pomocą modelowania statystycznego wyznaczono rozkład dodatkowych kosztów spowodowanych typowymi błędami parametrów wejściowych modeli optymalizacyjnych. Wyznaczono też rozkłady błędów funkcji kosztu i błędów określania obciążeń JW. Zbadano wrażliwość tych błędów na błędy parametrów wejściowych. Analizowano też dopuszczalny błąd niezbilansowania.

1.4. TWÓRCZE ELEMENTY ROZPRAWY

Do twórczych można zaliczyć następujące elementy rozprawy:

- opracowanie metodyki konstrukcji charakterystyk kosztów zmiennych jednostek wytwórczych, na bazie charakterystyk energetycznych, z uwzględnieniem kosztów gospodarczego wykorzystania środowiska naturalnego (podrozdział 4.3),
- opracowanie metodyki konstrukcji charakterystyk kosztów rozruchów jednostek wytwórczych, na bazie charakterystyk strat rozruchowych, z uwzględnieniem kosztów gospodarczego wykorzystania środowiska naturalnego (podrozdział 4.3),
- propozycję aproksymacji charakterystyk energetycznych i kosztowych jednostek wytwórczych za pomocą sieci neuronowych (podrozdz. 4.3.3 i podrozdz. D1.1 w dodatku 1),
- definicję operatora mutacji binarnej zależnej od liczby jednostek niezbędnych do pokrycia zapotrzebowania MB1 (podrozdz. 4.4.1.1.2),

- definicję operatora mutacji binarnej zależnej od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MB3 (podrozdz. 4.4.1.1.2) oraz jego wersji zmiennopozycyjnej (podrozdz. 4.5.1.2),
- definicję operatora transpozycji (podrozdz. 4.4.1.1.2),
- opracowanie strategii naprawy chromosomów niedopuszczalnych SN (podrozdz. 4.4.1.1.3),
- opracowanie strategii z funkcją kary SFK (podrozdz. 4.4.1.1.3),
- definicję zmiennych w algorytmach do ERO w wersji kombinowanej, w postaci czasów załączeń i odstawień jednostek wytwórczych oraz ich reprezentacji binarnej RB2 (podrozdz. 4.4.1.2.1) i całkowitoliczbowej RC (podrozdz. 4.4.1.3.1),
- modyfikację operatorów zmiennopozycyjnych do postaci operatorów całkowitoliczbowych: mutacji nierównomierniej MCN, krzyżowania arytmetycznego KCA i heurystycznego KCH (podrozdział. 4.4.1.3.2),
- opracowanie metody wyznaczania temperatury początkowej i współczynnika redukcji temperatury w schemacie Kirkpatricka (podrozdz. 4.4.2.1),
- opracowanie metody wyznaczania temperatur dopasowanych do poziomów kosztowych w schemacie Aartsa i modyfikację procesu schładzania Aartsa dla strategii z funkcją kary i naprawy (podrozdz. 4.4.2.1),
- opracowanie algorytmu hybrydowego symulowanego wyżarzania i algorytmu ewolucyjnego SW+AE (podrozdz. 4.4.3),
- opracowanie kompleksowego algorytmu ewolucyjnego KAE (podrozdz. 4.5.1),
- opracowanie strategii naprawy chromosomów niedopuszczalnych ze względu na warunek bilansu mocy: strategii z kryterium jednostkowych kosztów zmiennych SN1 oraz strategii z kryterium przyrostów względnych kosztów zmiennych SN2 (podrozdz. 4.5.1.3),
- opracowanie sekwencyjnego algorytmu ewolucyjnego SAE (podrozdz. 4.5.2),
- modyfikację proponowanych algorytmów optymalizacyjnych dla potrzeb ekonomicznego rozdziału obciążeń na poziomie systemu elektroenergetycznego, z uwzględnieniem strat sieciowych (podrozdz. 5),
- przeprowadzenie statystycznej analizy dokładności proponowanych modeli optymalizacyjnych (podrozdz. 4.6),
- opracowanie programów komputerowych implementujących zaprojektowane modele optymalizacyjne i programów pomocniczych (dodatek 8).

2. WPROWADZENIE DO ZAGADNIENI EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ I DOBORU SKŁADU JEDNOSTEK WYTWÓRCZYCH

Optymalizacja stanów pracy SEE w warunkach normalnych obejmuje szeroką klasę zagadnień [Ber86a], które można klasycznie podzielić na: optymalizację rozdziału obciążeń mocy czynnych, dobór składu jednostek wytwórczych, rozdział mocy biernych na źródła tych mocy oraz dobór nastaw przekładni transformatorów regulacyjnych (lub optymalizację napięć węzłowych). Za wskaźnik jakości optymalizacji normalnych stanów pracy SEE przyjmuje się sumę kosztów zmiennych wytwarzania energii elektrycznej w okresie optymalizacji T [Por96], [Ber86a]:

$$F(\mathbf{x}) = \int_0^T \sum_{i=1}^N \alpha_i(t) K_{zi} [P_{ni}(t)] dt + \sum_{i=1}^N K_{rTi} + \int_0^T \mu(t) P_w(t) dt \quad (2.1)$$

przy czym: $\mathbf{x} \in \mathbf{II}$, $t \in (0, T)$,

gdzie: \mathbf{x} – wektor zmiennych funkcji t ; T – okres (horyzont) optymalizacji w h; i – numer źródła wytwarzania; N – liczba dyspozycyjnych jednostek wytwórczych; $K_{zi} [P_{ni}(t)]$ – strumień kosztu wytwarzania i -tego bloku przy obciążeniu mocą P_{ni} , zł/h; P_{ni} – obciążenie czynne i -tego bloku netto w MW; $\alpha_i(t)$ – funkcja binarna przyjmująca wartość 1 gdy blok pracuje w chwili t lub 0 gdy blok znajduje się w rezerwie w chwili t ; K_{rTi} – całkowite koszty odstawienia, rozruchu i postoju i -tego bloku w okresie optymalizacji T , zł; $\mu(t) P_w(t)$ – koszt wymiany mocy czynnej P_w w zł; $\mu(t)$ – funkcja kosztów jednostkowych wymiany mocy, zł/(MW·h); \mathbf{II} – dopuszczalny zbiór zmiennych określony nierównościami wynikającymi z warunków dopuszczalnych pracy elementów SEE i równaniami bilansów mocy, bilansów wody zbiorników itp.

Wektor zmiennych \mathbf{x} dobierany jest w zależności od stopnia uproszczenia zadania (może obejmować min. obciążenia czynne i bierne jednostek wytwórczych w kolejnych chwilach okresu optymalizacji, kombinacje pracujących jednostek w każdej chwili t , zmienne opisujące konfigurację sieci przesyłowej, przekładnie transformatorów). Zbiór \mathbf{II} określają m.in.:

- równanie bilansu mocy zapotrzebowanej,
- równania i nierówności opisujące gospodarkę wodną w zbiornikach elektrowni wodnych,
- nierówności opisujące ograniczenia produkcji mocy biernej w generatorach i kompensatorach,
- ograniczenia przekładni transformatorów regulacyjnych,
- ograniczenia napięciowe w węzłach systemu,
- ograniczenia prądów nominalnych i zwarciovych w elementach systemu,
- utrzymanie wymaganej rezerwy mocy (wirującej, gorącej i zimnej),
- nierówności opisujące ograniczenia mocy czynnej poszczególnych jednostek,
- status pracy jednostek,

- minimalne okresy postojów i pracy bloków energetycznych,
- czasy rozruchów jednostek,
- maksymalna liczba bloków, które można jednocześnie uruchomić w jednej elektrowni,
- dopuszczalna liczba cykli rozruch – odstawienie bloków w okresie T ,
- zdolności pracy jednostek z mocami powyżej P_{nmax} i poniżej P_{nmin} ,
- ograniczenia emisji zanieczyszczeń itp.

Jak zaznaczono we wstępie, dla rzeczywistych SEE zadanie optymalizacyjne – $\min_{x \in \Pi, t \in \{0, T\}} F(x)$ – sformułowane powyżej jest zbyt skomplikowane (setki ciągłych i dyskretnych funkcji czasu, zbyt duża liczba ograniczeń) i praktycznie trudne do rozwiązania. W związku z tym dekomponuje się je na prostsze suboptymalizacyjne zadania cząstkowe [Ber96a]:

- dobór składu jednostek wytwórczych,
- rozdział obciążeń czynnych między elektrownie (bloki) ciepłe przy zadanym składzie jednostek – ERO-P „w punkcie”,
- optymalizację poziomów napięć i rozdziału mocy biernej (ERO-Q) przy zadanym rozdziale mocy czynnych,
- plan pracy elektrowni wodnych.

Poniżej opisano klasyczne sposoby rozwiązania zadania ERO-P metodą mnożników Lagrange’a i metodą programowania dynamicznego oraz DSJW metodą charakterystyk czasów granicznych. Metoda mnożników Lagrange’a i charakterystyk czasów granicznych stosowane były przez wiele lat do optymalizacji rozdziału obciążeń w warunkach krajowych [Gła75].

2.1. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ CZYNNYCH METODĄ MNOŻNIKÓW LAGRANGE’A [GŁA99]

Wstępnie zakłada się:

- w SEE pracują wyłącznie elektrownie ciepłe, w których skład urządzeń jest znany i niezmienny w okresie optymalizacji,
- wszystkie bloki pracują w stanie ustalonym,
- zmienne moce jednostek wytwórczych nie mają ograniczeń (założenie teoretyczne, nie mające wpływu na istotę metody),
- zapotrzebowanie na łączną moc dostarczaną odbiorcom P_z stanowi sumę zapotrzebowania na moc poszczególnych węzłów.

Minimalizowany jest strumień kosztu paliwa w systemie:

$$F = \sum_{i=1}^N K_{zi}(P_{ni}) \quad (2.2)$$

przy warunku bilansu mocy czynnych:

$$\sum_{i=1}^N P_{ni} - P_z - \Delta P_s = 0 \quad (2.3)$$

gdzie: P_z – moc czynna zapotrzebowana; ΔP_s – straty mocy w systemie (w sieci przesyłowej).

W zadaniach znajdowania ekstremum funkcji N zmiennych przy równościowych warunkach ograniczających (2.3) korzysta się z metody mnożników Lagrange’a [Fin73], według której tworzy się liniową kombinację funkcji celu i warunków ograniczających:

$$L = \sum_{i=1}^N K_{zi}(P_{ni}) - \lambda \left(\sum_{i=1}^N P_{ni} - P_z - \Delta P_s \right) \quad (2.4)$$

gdzie: λ – nieoznaczony mnożnik Lagrange’a.

Postępowanie takie zgodne jest z twierdzeniem Kuhna – Tuckera mówiącym o tym, że minimum warunkowe funkcji postaci (2.2) w obszarze ograniczeń (2.3) (możliwe są też ograniczenia nierównościowe) występuje w tym samym punkcie, co punkt siodłowy lagranżianu utworzonego jako kombinacja liniowa funkcji (2.2) i lewych stron warunków ograniczających.

Warunkiem koniecznym dla istnienia ekstremum funkcji (2.2) w punkcie $(P_{n1}, P_{n2}, \dots, P_{nN})$ jest spełnienie układu równań z $N + 1$ niewiadomymi: $P_{n1}, P_{n2}, \dots, P_{nN}$ i λ :

$$\frac{\partial L}{\partial P_{ni}} = \frac{dK_{zi}(P_{ni})}{dP_{ni}} - \lambda \left(1 - \frac{\partial \Delta P_s}{\partial P_{ni}} \right) = 0, \quad i = 1, 2, \dots, N \quad (2.5)$$

przy zachowaniu bilansu mocy (2.3).

Wprowadzając oznaczenia:

$$\varepsilon_{ki} = \frac{dK_{zi}(P_{ni})}{dP_{ni}} - \text{przyrost względny strumienia kosztów zmiennych } i\text{-tego bloku}$$

w zł/(MW·h),

$$\sigma_i = \frac{\partial \Delta P_s}{\partial P_{ni}} - \text{przyrost względny strat sieciowych przy małej zmianie mocy } P_{ni},$$

otrzymamy warunek ekonomicznego rozdziału obciążenia mocą czynną:

$$\frac{\varepsilon_{k1}}{1 - \sigma_1} = \frac{\varepsilon_{k2}}{1 - \sigma_2} = \dots = \frac{\varepsilon_{kN}}{1 - \sigma_N} = \lambda = \varepsilon_{ko} \quad (2.6)$$

lub przy pominięciu strat sieciowych:

$$\varepsilon_{k1} = \varepsilon_{k2} = \dots = \varepsilon_{kN} = \varepsilon_{kw} \quad (2.7)$$

gdzie: ε_{ko} – przyrost względny liczony z uwzględnieniem strat sieciowych, tj. na poziomie odbiorcy, zł/(MW·h); ε_{kw} – przyrost względny liczony na poziomie wytwarzania netto w zł/(MW·h); $\frac{1}{1-\sigma_i} = k'_i$ – tzw. współczynnik karny ze względu na straty sieciowe.

Ograniczenia na moce czynne jednostek w postaci:

$$P_{n\min i} \leq P_{ni} \leq P_{n\max i} \quad i = 1, 2, \dots, N \quad (2.8)$$

uwzględnia się modyfikując charakterystyki przyrostów względnych. Krzywe $\varepsilon_{ki} = f(P_{ni})$ bloków uzupełnia się prostymi:

- na lewym krańcu przedziału $P_{n\min i} \div P_{n\max i}$: $P_{ni} = P_{n\min i}$ dla $\varepsilon_{ki} \leq \varepsilon_{k\min i}$,
- na prawym krańcu tego przedziału: $P_{ni} = P_{n\max i}$ dla $\varepsilon_{ki} \geq \varepsilon_{k\max i}$,

gdzie: $P_{n\min i}$ – minimum techniczne i -tej JW w MW; $P_{n\max i}$ – moc osiągalna i -tej JW w MW; $\varepsilon_{k\min i}$ – minimalny przyrost względny strumienia kosztów zmiennych i -tej JW (dla minimum technicznego) w zł/(MW·h); $\varepsilon_{k\max i}$ – maksymalny przyrost względny strumienia kosztów zmiennych i -tej JW (dla mocy osiągalnej) w zł/(MW·h).

Warunek dostateczny istnienia minimum lokalnego funkcji (2.2) przy warunku ograniczającym (2.3) wymaga ściślejszej wypukłości charakterystyk kosztowych wszystkich JW. Wymaganie to jest spełnione tylko częściowo, ponieważ charakterystyki JW mają na ogół punkty skokowych zmian wartości, spowodowane obecnością zaworów regulacyjnych turbin. W praktyce kontroluje się jedynie warunki konieczne istnienia ekstremum.

Przeprowadzone rozważania można podsumować następująco: **minimum kosztów zmiennych związanych z produkcją energii elektrycznej uzyskuje się przy takim rozłożeniu mocy zapotrzebowanej na bloki energetyczne (elektrownie), aby przyrosty względne strumienia kosztów zmiennych bloków (elektrowni) były równe, przy zachowaniu bilansu mocy.**

Uwzględnienie strat sieciowych sprowadza się do obliczania współczynników karnych k'_i , podlegających zmianom wraz ze zmianami zachodzącymi w SEE. Poniżej przedstawiono podstawową metodę obliczania pochodnych (lub przyrostów względnych) strat sieciowych $\frac{\partial \Delta P_s}{\partial P_{ni}}$, zaproponowaną przez Gornstiejna [Gła80a].

Mając daną zależność na straty mocy czynnej w linii:

$$\Delta P_l = \frac{P_l^2 + Q_l^2}{U_l^2} R_l \quad (2.9)$$

oraz znając współczynniki rozptywu mocy w linii l -tej, przy małych zmianach mocy czynnej w elektrowni i -tej, otrzymuje się następujący wzór na przyrost względny strat w całej sieci, pochodzących od zmian mocy P_{ni} w i -tym węźle:

$$\frac{\partial \Delta P_s}{\partial P_{ni}} = \sum_{l=1}^L \frac{\partial \Delta P_l}{\partial P_{ni}} = \sum_{l=1}^L \frac{2P_l v'_{il} + 2Q_l v''_{il}}{U_l^2} R_l \quad (2.10)$$

gdzie: P_l, Q_l, U_l – odpowiednio moc czynna, bierna i napięcie na końcu l -tego elementu ($l = 1, 2, \dots, L$); R_l – rezystancja l -tego elementu; v'_{il}, v''_{il} – współczynniki rozptywów mocy czynnej i biernej w l -tym elemencie wskutek zmian mocy czynnej w i -tym węźle:

$$v'_{il} = \frac{\partial P_l}{\partial P_{ni}} \quad \text{oraz} \quad v''_{il} = \frac{\partial Q_l}{\partial P_{ni}}.$$

Przy założeniu $v'_{il} \gg v''_{il}$ można napisać:

$$\frac{\partial \Delta P_s}{\partial P_{ni}} = \sum_{l=1}^L \frac{2P_l v'_{il}}{U_l^2} R_l \quad (2.11)$$

Przedstawiona metoda jest szczególnie przydatna w prostych przypadkach, zwłaszcza w zastosowaniu do sieci promieniowych. Obliczone wartości pochodnych strat wyznaczane są dla określonego stanu pracy sieci. Dotyczy to zresztą i innych metod. Aby w praktyce uwzględnić straty sieciowe najlepiej liczyć je na bieżąco, na podstawie aktualnego stanu pracy sieci. Inne metody obliczania strat sieciowych opisano w pracach [Gła80a] i [Kł60]: metodę współczynników strat sieciowych B_{mn} (szerzej sposób obliczania tych współczynników opisano w pracy [Kł62c]; metoda ta jest często używana do modelowania strat sieciowych w wielu współczesnych algorytmach ERO, np. [Lee02], [Yal01], [Lee98], [Roa00], [Ara02], [Hot00]), metodę przesunięć kątów fazowych Brownleego oraz metodę Mielnikowa. Wszystkie wymienione metody wymagają istotnych założeń upraszczających i dają rozwiązania przybliżone.

Stosując metodę ERO według równych przyrostów względnych kosztów zmiennych, bez uwzględnienia strat sieciowych, uzyskuje się oszczędności w granicach 0,5% kosztów produkcji, co przy cenach węgla z 1998 r. daje roczne oszczędności rzędu 43 mln zł [Gła99]. Wpływ strat sieciowych w obliczeniach ERO jest odczuwalny w dużych systemach, z długimi liniami przesyłowymi. W systemie krajowym uwzględnienie strat sieciowych w ERO, jak wykazały badania przeprowadzone przez Instytut Energetyki w latach sześćdziesiątych, daje oszczędności na poziomie ok. 0,1% kosztów produkcji. Wpływ strat sieciowych na ERO i związane z tym koszty analizowano szczegółowo w [Prz70]. Dla SEE wykonano obliczenia ERO z uwzględnieniem (w postaci współczynników karnych) i bez uwzględnienia strat sieciowych. Dzięki uwzględnieniu strat w obliczeniach, zredukowano je o ok. 4% i zmniejszono koszty wytwarzania o ok. 0,015%.

Warto zwrócić uwagę, że metoda ERO według równych przyrostów względnych kosztów zmiennych pozwala na przeprowadzenie optymalizacji chwilowych (ERO „w punkcie”) i nie uwzględnia kosztów odstawień i rozruchów źródeł, ponadto wymaga ciągłych, różniczkowalnych, wypukłych i podanych w postaci analitycznej charakterystyk kosztowych bloków energetycznych. Rozwiązanie jest zależne od zbioru branych do obliczeń jednostek wytwórczych. Optymalizacja doboru jednostek do tego zbioru dokonywana jest inną metodą. Szczegółowy algorytm ERO metodą równych przyrostów względnych kosztów zmiennych, w wersji bez uwzględniania strat sieciowych, zamieszczono w podrozdziale 4.2.

2.2. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ CZYNNYCH METODĄ PROGRAMOWANIA DYNAMICZNEGO

Programowanie dynamiczne zostało opracowane dla klasy procesów alokacji występujących w ekonomii matematycznej i badaniach operacyjnych. W zadaniu alokacji chodzi o najbardziej efektywny sposób użytkowania zasobów (siły roboczej, pieniędzy, maszyn, paliwa itp.). Każde możliwe zastosowanie zasobu nazywa się działalnością. W wyniku użytkowania całego lub części zasobu na określoną działalność, otrzymujemy pewien przychód. Wielkość przychodu zależy od wielkości zużytego zasobu oraz od rodzaju działalności. W procesie alokacji dokonuje się pewnych założeń wstępnych:

- przychody z różnych działalności dają się zmierzyć tą samą jednostką miary,
- przychód z dowolnej działalności jest niezależny od przydzielenia zasobów na inne rodzaje działalności,
- przychód całkowity jest sumą przychodów indywidualnych.

Liczbę działalności oznaczmy przez N i wyliczamy je w ustalonej kolejności: $i = 1, 2, \dots, N$. Z każdą działalnością związana jest pewna funkcja przychodu $g_i(x_i)$, zależna od ilości zasobu zużytego na i -tą działalność x_i . Założenia niezależności poszczególnych działalności i addytywności odpowiednich przychodów prowadzą do wyrażenia:

$$R(x_1, x_2, \dots, x_N) = \sum_{i=1}^N g_i(x_i) \quad (2.12)$$

gdzie: $R(x_1, x_2, \dots, x_N)$ – całkowity przychód procesu alokacji.

Oznaczając całkowitą ilość zasobów przez s otrzymujemy warunek ograniczający: $\sum_{i=1}^N x_i = s$,

przy czym $x_i > 0$. Szukamy maksymalnej lub minimalnej wartości funkcji $R(x_1, x_2, \dots, x_N)$ na zbiorze wszystkich wartości x_i spełniających podane warunki.

Omówione powyżej zagadnienie optymalizacji można rozpatrywać w odniesieniu do ERO. Zasobem, który należy rozdzielić jest prognozowane obciążenie systemu elektroenergetycznego P_z . Działalność to przydzielenie określonego obciążenia i -tej spośród N jednostek wytwórczych ($i = 1, 2, \dots, N$). Obciążenie i -tej JW powoduje koszty związane z

produkcją energii elektrycznej. Całkowity koszt jest sumą kosztów składowych produkcji energii przez wszystkie JW. Warunek ograniczający dotyczy bilansu mocy elektrycznej.

W programowaniu dynamicznym procesowi nadaje się sztucznie własność pozornie czasową, dokonując alokacji pojedynczo. Najpierw przeznaczona się pewną ilość zasobu na N -tą działalność, potem na $(N - 1)$ -wszą działalność itd. Jeżeli rozpatrujemy działanie w ten sposób, mamy dynamiczny proces alokacji [Bel67]. Minimum funkcji (2.12) zależy od rozpatrywanej liczby działalności N oraz wielkości zasobu s . Wprowadza się ciąg funkcji $\{f_N(s)\}$ zdefiniowany dla $N = 1, 2, \dots, s \geq 0$ w następujący sposób:

$$f_N(s) = \min_{\{x_i\}} R(x_1, x_2, \dots, x_N) \quad (2.13)$$

gdzie: $x_i \geq 0, \sum_{i=1}^N x_i = s$.

Funkcja $f_N(s)$ tak określona jest minimalnym kosztem alokacji zasobów w rozmiarze s między N rodzajów działalności.

Niech x_N , zawarte w przedziale $0 \leq x_N \leq s$, będzie alokacją przeprowadzoną w N -tej działalności. Pozostała ilość zasobu wynosząca $(s - x_N)$ zostanie zużyta w taki sposób, aby dała najmniejsze koszty z pozostałych $(N - 1)$ działalnościach. Optymalnym wyborem x_N jest taki wybór, który minimalizuje koszt związany z początkową alokacją zasobu x_N w N -tej działalności. Podstawowe rekurencyjne równanie funkcyjne optymalizacji ma postać [Bel67]:

$$f_N(s) = \min_{0 \leq x_N \leq s} [g_N(x_N) + f_{N-1}(s - x_N)] \quad (2.14)$$

dla $N = 2, 3, \dots, s \geq 0$, przy czym $f_1(s) = g_1(s)$.

Wzór (2.14) zgodny jest z tzw. zasadą optymalności [Bel67]: polityka optymalna ma tę własność, że niezależnie od początkowego stanu i początkowej decyzji pozostałe decyzje muszą stanowić politykę optymalną ze względu na stan wynikający z pierwszej decyzji.

Równanie rekurencyjne (2.14) pozwala uzyskać ciąg $\{f_N(s)\}$ przez indukcję, gdy znana jest $f_1(s)$. Metoda wymaga dyskretyzacji zasobu s : $s = 0, \Delta, 2\Delta, \dots, R\Delta$, przy czym całkowita ilość zasobu $x_c = R\Delta$. Każdy element ciągu $\{f_N(s)\}$ zostanie obliczony i stabilizowany dla każdego s . W zagadnieniu alokacji jest dogodnie, aby zmienna x_N charakteryzująca alokację przybierała dokładnie te same wartości, co zmienna s .

Według [Bel67] metoda programowania dynamicznego daje zawsze minimum absolutne, a nie lokalne. Ograniczenia występujące często w praktyce, nie tylko nie komplikują zagadnienia, ale znacznie je upraszczają ograniczając ilość różnych możliwości na każdym etapie obliczeń. Ponadto, inaczej jak w metodach opartych na rachunku różniczkowym, funkcje kosztów nie muszą być dane w postaci analitycznej, a osobliwości pochodnych są nieistotne.

Rozwiązując zadanie ERO metodą programowania dynamicznego szukamy minimum funkcji (2.2), przy warunku bilansu mocy i z uwzględnieniem zakresu zmienności obciążeń (2.9). Algorytm ERO metodą programowania dynamicznego przedstawiono poniżej.

1. Należy przyjąć zbiór N bloków, na które może być rozdzielone obciążenie P_z , wczytać charakterystyki kosztów zmiennych JW – $K_{zi}(P_{ni})$ oraz ustalić krok Δ .
2. Obliczenia dla kolejnego etapu: $i = 1$ do N
 - 2.1. Obliczenia dla kolejnej wartości obciążenia systemu: $P_{zj} = 0$ do P_z z krokiem Δ .
 - 2.1.1. Sprawdzenie czy rozpatrywane obciążenie systemu P_{zj} mieści się w granicach dopuszczalnego zakresu zmienności, którego dolna granica równa jest najmniejszemu minimum technicznemu spośród i (rozpatrywanych na kolejnych etapach) bloków, a granica górna – sumie maksymalnych obciążeń tychże bloków. Jeśli warunki nie są spełnione, powrót odpowiednio do punktu 2.1 lub 2.
 - 2.1.2. Ustawienie wartości strumienia kosztu minimalnego dla rozpatrywanej mocy systemu i rozpatrywanego etapu na wartość $K_{\Sigma \min}(P_{zj}, i) = \infty$.
 - 2.1.3. Obliczenia dla kolejnej wartości obciążenia i -tego bloku, który rozpatrywany jest na bieżącym etapie: $P_{ni} = \{0, P_{nmini}, P_{nmini} + \Delta, P_{nmini} + 2\Delta, \dots, P_{nmaxi}\}$.
 - 2.1.3.1. Obliczenie strumienia kosztów zmiennych przy liczbie bloków i , przy mocy systemu P_{zj} i obciążeniu i -tego bloku mocą P_{ni} oraz optymalnym rozłożeniu mocy $(P_{zj} - P_{ni})$ na pozostałe bloki: $K_{\Sigma} = K_{zi}(P_{ni}) + K_{\Sigma \min}(P_{zj} - P_{ni}, i - 1)$. Dla etapu $i = 1$ należy przyjąć $K_{\Sigma}(P_{zj} - P_{ni}, 0) = 0$.
 - 2.1.3.2. Jeśli obliczona wartość $K_{\Sigma} < K_{\Sigma \min}(P_{zj}, i) \Rightarrow K_{\Sigma \min}(P_{zj}, i) = K_{\Sigma}$, $P_{nio}(P_{zj}) = P_{ni}$, przy czym $P_{nio}(P_{zj})$ oznacza optymalną wartość obciążenia bloku i -tego na bieżącym etapie poszukiwań.
3. Wyprowadzenie wyników w postaci tablicy zawierającej wartości $K_{\Sigma \min}(P_{zj}, i)$ oraz $P_{nio}(P_{zj})$:

Nr jednostki P_{zj}	1	2	...	$N - 1$	N
0	$P_{n1o}(0)$ $K_{\Sigma \min}(0, 1)$	$P_{n2o}(0)$ $K_{\Sigma \min}(0, 2)$...	$P_{n(N-1)o}(0)$ $K_{\Sigma \min}(0, N-1)$	$P_{nNo}(0)$ $K_{\Sigma \min}(0, N)$
Δ	$P_{n1o}(\Delta)$ $K_{\Sigma \min}(\Delta, 1)$	$P_{n2o}(\Delta)$ $K_{\Sigma \min}(\Delta, 2)$...	$P_{n(N-1)o}(\Delta)$ $K_{\Sigma \min}(\Delta, N-1)$	$P_{nNo}(\Delta)$ $K_{\Sigma \min}(\Delta, N)$
...
P_z	$P_{n1o}(P_z)$ $K_{\Sigma \min}(P_z, 1)$	$P_{n2o}(P_z)$ $K_{\Sigma \min}(P_z, 2)$...	$P_{n(N-1)o}(P_z)$ $K_{\Sigma \min}(P_z, N-1)$	$P_{nNo}(P_z)$ $K_{\Sigma \min}(P_z, N)$

Wykorzystanie tak skonstruowanej tablicy do rozwiązania postawionego zadania stanowi drugą fazę obliczeń. Ostatni wiersz kolumny N prezentuje minimalny koszt dla procesu obejmującego rozdział obciążenia P_z na N bloków oraz optymalną wartość obciążenia N -tego bloku – P_{nNo} . Wartość ta określa obciążenie systemu, które należy rozłożyć optymalnie na pozostałe $(N-1)$ bloków – $P_{zj} = (P_z - P_{nNo})$. Kolumna $(N-1)$ zawiera w wierszu $P_{zj} = (P_z - P_{nNo})$ optymalne obciążenie bloku $(N-1)$ -go – $P_{n(N-1)o}$. Analogicznie kolumna $(N-2)$ w wierszu $P_{zj} = (P_z - P_{nNo} - P_{n(N-1)o})$ zawiera optymalne obciążenie bloku $(N-2)$ -go. W ten sposób odczytujemy ekonomiczne obciążenia poszczególnych bloków. Obciążenia te w niektórych przypadkach mogą być zerowe, co oznacza, że blok jest odstawiony. Optymalizowane są więc nie tylko obciążenia jednostek (jak w ERO metoda równych przyrostów względnych kosztów zmiennych), ale także ich skład. Optymalizacja składu i obciążeń odbywa się dla konkretnej mocy zapotrzebowanej P_z , tzn. „w punkcie”. Optymalizacja w horyzoncie T dokonywana jest w sposób sekwencyjny, poprzez optymalizację dla kolejnych chwil t okresu T . Otrzymujemy w ten sposób rozwiązania optymalne dla tych chwil, ale nieoptymalne z punktu widzenia całego okresu T . Może dojść do sytuacji odstawienia bloku w chwili t i jego ponownego załączenia w chwili $t+1$, co jest technicznie nierealne. Z sekwencyjną realizacją ERO związany jest problem uwzględnienia kosztów rozruchu. Z decyzją o odstawieniu JW w chwili t powinny być związane koszty jej rozruchu po czasie postoju t_p . Koszty te jednak, przy sekwencyjnej realizacji ERO są niewiadome, ponieważ w chwili t nie znamy stanów optymalnych dla chwil $t+1$, $t+2$, ... i nie możemy określić czasu postoju JW w rezerwie. Zaletą metody jest brak ograniczeń co do matematycznej postaci funkcji kosztu i charakterystyk kosztowych bloków. Zastosowanie programowania dynamicznego do zadania ERO można znaleźć w [Brz95b], [Low66] i [Kul80].

2.3. DOBÓR SKŁADU JEDNOSTEK WYTWÓRCZYCH METODĄ CHARAKTERYSTYK CZASÓW GRANICZNYCH

Zadanie doboru składu jednostek wytwórczych należy do klasy problemów optymalizacji kombinatorycznej, w której poszukuje się optymalnej wartości funkcji kosztu zdefiniowanej w przeliczalnej przestrzeni rozwiązań. Zadanie sprowadza się do wyznaczenia czasów wyłączeń i załączeń współpracujących bloków energetycznych w przyjętym okresie optymalizacji T .

Istota problemu wiąże się z faktem braku możliwości pokrycia obciążenia w dolinie nocnej (ok. 70 – 75% obciążenia szczytowego), bez odstawienia urządzeń wytwórczych. Przyczyną tego są na ogół wysokie minima techniczne bloków energetycznych oraz duża liczba elektrociepłowni pracujących z wymuszonym przebiegiem obciążenia, z uwagi na zapewnienie pokrycia dostaw ciepła do celów grzewczych i pary technologicznej [Gła99].

Analizując ekonomikę odstawień bloków do rezerwy, określa się wypadkową zmianę kosztów zmiennych systemu w wyniku odstawienia i -tej jednostki [Jan92], [Ber86a]:

$$\Delta K_i(t_{wi}, t_{zi}) \approx \int_{t_{wi}}^{t_{zi}} \Delta K_{si}(t) dt - K_{ri}(t_{pi}) \quad (2.15)$$

przy czym:

$$\Delta K_{si} = K_{zi}(P_{ni}) - \delta K_{si} = K_{zi}(P_{ni}) - \varepsilon_{ks} P_{ni} \quad (2.16)$$

gdzie: ΔK_{si} – zmiana strumienia kosztu zmiennego systemu po odstawieniu jednostki i -tej do rezerwy w zł/h; $\delta K_{si} = \varepsilon_{ks} P_{ni}$ – wzrost strumienia kosztów zmiennych systemu spowodowany wzrostem obciążenia pozostałych bloków po odstawieniu bloku i -tego, zł/h; ε_{ks} – w przybliżeniu przyrost względny strumienia kosztów systemu przy obciążeniu P_z , przy którym następuje odstawienie jednostki i -tej, w zł/(MW·h); t_{wi}, t_{zi} – czasy wyłączenia i załączenia jednostki i -tej.

Poszukuje się czasów t_{wi} oraz t_{zi} , dla których funkcja (2.15) ma maksymalną, dodatnią wartość.

W praktyce do optymalizacji składu JW w warunkach krajowych, od lat 60-tych, stosowana była metoda charakterystyk czasów granicznych autorstwa M. Toronia [Tor62], którą opisano poniżej. Przyjmuje się założenie, że przyrost względny strumienia kosztów zmiennych w SEE nie ulega zmianie po odstawieniu lub uruchomieniu jednostki wytwórczej, ponieważ moc tej jednostki w porównaniu z mocą sumaryczną pozostałych jednostek jest niewielka. Zaniedbując zmienność strumienia zysku podczas odstawienia bądź załączenia i -tej jednostki (całka we wzorze (2.15)), którą w praktyce trudno jest dokładnie ustalić, można napisać następujące kryteria dotyczące korzyści z odstawienia (2.17) lub uruchomienia (2.18) jednostki i -tej:

$$Z_{oi}(t, t_{pi}) = [K_{zi}(P_{ni}) - \varepsilon_{ks} P_{ni}] t_{pi} - K_{ri}(t_{pi}) \geq 0 \quad (2.17)$$

$$Z_{ui}(t, t_{ri}) = [\varepsilon_{ks} P_{ni} - K_{zi}(P_{ni})] t_{ri} - K_{ri}(t_{ri}) \geq 0 \quad (2.18)$$

gdzie: t – chwila odstawienia lub uruchomienia jednostki; t_{pi}, t_{ri} – czas postoju i czas pracy po uruchomieniu jednostki i -tej w h.


Pierwszy składnik w nierówności (2.17) oznacza zysk po odstawieniu i -tej JW na czas t_{pi} , natomiast drugi – wzrost kosztów zmiennych pozostałych jednostek związany z przejściem przez nie mocy P_{ni} . Podobnie w nierówności (2.18) pierwszy składnik oznacza zysk związany z odciążeniem pracujących JW o wartość mocy P_{ni} , natomiast drugi składnik – koszty zmienne jednostki i -tej.

Z nierówności (2.17) i (2.18) określa się czasy graniczne odstawienia (2.19) lub uruchomienia (2.20), tj. najkrótsze czasy, na jakie opłaca się ze względów ekonomicznych jednostkę odstawić lub uruchomić:

$$t_{pig} = \frac{K_{ri}(t_{pi})}{K_{zi}(P_{ni}) - \varepsilon_{ks} P_{ni}} \quad (2.19)$$

$$t_{rig} = \frac{K_{ri}(t_{pi})}{\varepsilon_{ks} P_{ni} - K_{zi}(P_{ni})} \quad (2.20)$$

Na podstawie tych wzorów można sporządzić wykresy zależności $t_{pig}(\varepsilon_{ks})$ oraz $t_{rig}(\varepsilon_{ks})$, mające przebieg hiperboliczny, przy czym dla tej ostatniej funkcji, z uwagi na istniejącą zależność od czasu postoju jednostki w rezerwie przed uruchomieniem, otrzymuje się rodzinę krzywych (rys. 2.1).



Rys. 2.1. Charakterystyki czasów granicznych; po prawej stronie dla uruchamiania, po lewej – dla odstawiania [Gła99].

Czasy graniczne zmierzają do nieskończoności, gdy mianownik w równaniu (2.19) i (2.20) jest równy zero, czyli przy przyroście względnym systemu:

$$\varepsilon_{ksig} = \frac{K_{zi}(P_{ni})}{P_{ni}} = k_{ji} \quad (2.21)$$

który nazwano przyrostem granicznym. Przy rozdziale obciążeń metodą równych przyrostów względnych kosztów zmiennych zachodzi $\varepsilon_{ks} = \varepsilon_{ki}$, co wobec (2.21) oznacza, że w punkcie granicznym przyrost względny i jednostkowy koszt zmienny k_{ji} bloku i -tego są sobie równe. Charakterystyki $\varepsilon_{ki} = f(P_{ni})$ oraz $k_{ji} = f(P_{ni})$ przecinają się tylko w jednym punkcie – obciążeniu ekonomicznym bloku P_{nei} , więc można zapisać:

$$\varepsilon_{ksig} = k_{ji}(P_{nei}) \quad (2.22)$$

Sens fizyczny przyrostu względnego granicznego jest następujący. Jeśli system pracuje przy przyroście względnym $\varepsilon_{ks} > \varepsilon_{ksig}$, to o opłacalności uruchomienia danej JW można mówić wówczas, gdy przewidywany czas uruchomienia jest większy, niż czas graniczny na krzywej $t_{rig}(\varepsilon_{ks})$ (po określonym czasie postoju w rezerwie). Jeśli natomiast system pracuje przy przyroście względnym $\varepsilon_{ks} < \varepsilon_{ksig}$, odstawienie JW opłacalne jest wówczas, gdy przewidywany czas odstawienia będzie większy, niż czas graniczny na krzywej $t_{pig}(\varepsilon_{ks})$.

W praktyce dyspozytorskiej sporządza się tzw. tablice uruchamiania i odstawiania jednostek na poszczególne strefy doby (z uwzględnieniem czasu postoju w przypadku uruchamiania). Np. jeśli czas pracy bloku po załączeniu wynosi $t_r = 4$ h, z charakterystyk czasów granicznych odnotowuje się wartość ε_{ki} dla każdej JW, biorąc pod uwagę czasy postojów w rezerwie. Kolejność uruchamiania jednostek uzyskuje się szeregując je wg przyrostów względnych, od najmniejszych do największych. Przy odstawianiu będzie to uszeregowanie odwrotne. Szczegółowy algorytm DSJW metodą charakterystyk czasów granicznych przedstawiono w podrozdziale 4.4.4.1.

Analizę korzyści z odstawiania i uruchamiania jednostek wytwórczych w SEE, z uwzględnieniem zmiany przyrostu względnego systemu spowodowanego odstawieniem lub załączeniem jednostki, podjęto w pracy [Tor66]. Z przeprowadzonych przez autorów obliczeń wynika, że zmiana przyrostu względnego w systemie po odstawieniu lub uruchomieniu JW, może być stosunkowo duża. W takiej sytuacji określa się dwa punkty graniczne: pierwszemu odpowiada przyrost względny systemu ε_{ksig1} bezpośrednio przed odstawieniem lub po uruchomieniu jednostki, drugiemu – przyrost względny ε_{ksig2} przed uruchomieniem lub po odstawieniu. Minimalny jednostkowy koszt zmienny odstawianego (załączanego) bloku – $k_{ji}(P_{nei})$, który determinuje momenty odstawienia lub uruchomienia bloku jest liczbowo równy pewnemu przyrostowi z przedziału $\varepsilon_{ksig1} \div \varepsilon_{ksig2}$.

W doborze zestawu urządzeń wytwórczych należy uwzględnić wiele ograniczeń technicznych, takich jak: minimalny czas, na jaki ze względów technicznych wolno odstawić lub załączyć jednostkę, wymuszona praca jednostki, czas trwania procesu uruchamiania i odstawiania, koordynacja odstawień i uruchomień między różnymi częściami doby, utrzymanie odpowiedniej rezerwy mocy itp. W praktyce alternatywą odstawienia może być zaniżanie obciążenia bloków na krótkie okresy poniżej minimum technicznego i zasilanie ich drogim mazutem.

3. PRZEGLĄD LITERATURY I STANU BADAŃ W ZAKRESIE EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ I DOBORU SKŁADU JEDNOSTEK WYTWÓRCZYCH

Początki problematyki ekonomicznego rozdziału obciążeń sięgają lat 20-tych XX-go wieku [Hap77]. Stosowane wówczas podejścia polegały na szeregowaniu urządzeń według sprawności i dociążaniu w pierwszej kolejności urządzeń o sprawnościach najwyższych. Idea obciążania przyrostowego (*incremental loading*), zaproponowana w roku 1930 [Sta30], polegała na dociążaniu tej jednostki, która charakteryzowała się najniższym przyrostem względnym kosztu paliwa w aktualnym punkcie pracy. W rok później odkryto zasadę funkcjonującą do dziś, że minimum kosztów osiąga się przy równości przyrostów względnych współpracujących urządzeń (np. [Hah31]). Uwzględnienie strat sieciowych w ERO rozważano po raz pierwszy w [Ste34], a szczególnie wnikliwie zajmowano się tym problemem w latach 40-tych i 50-tych. Z początkiem lat 50-tych wprowadzono pojęcie współczynnika karnego ze względu na straty sieciowe (*transmission loss penalty factor*) [Hap77].

Wobec ciągle rosnących mocy obliczeniowych komputerów i doskonalenia metod optymalizacyjnych w ostatnich latach, podejmuje się próby łącznego rozwiązania zadań ERO mocy czynnych, biernych i rozptywu mocy. Wektor poszukiwanych zmiennych sterujących x zawiera moce czynne generowane, regulowane napięcia węzłowe i regulowane przekładnie transformatorów. Podejście takie nosi nazwę optymalnego rozptywu mocy (*optimal load flow*). Problem ten został po raz pierwszy zdefiniowany przez Carpentiera na początku lat 60-tych [Car62]. Przegląd klasycznych metod optymalizacji rozptywu mocy można znaleźć w [Mom99a] i [Mom99b].

Odrębną kwestię stanowi optymalizacja pracy SEE na rynku energii elektrycznej (REE). Problem ten jest ściśle związany z przyjętym modelem REE i wynikającymi stąd kryteriami optymalizacji. Tematykę rozdziału obciążeń w warunkach REE w Polsce podejmowano w wielu publikacjach [Kło94], [Gła94], [Gła95], [Kąd96], [Jan96], [Poł96], [Gła96], [Gła97], [Poł99]. Wiele z zaproponowanych rozwiązań optymalizacyjnych jest już nieaktualnych, wobec przejściowych procesów kształtowania się REE w Polsce, hamowanych ograniczeniem konkurencji poprzez realizację kontraktów długoterminowych i innymi czynnikami. Jak zaznaczono w [Mie00]: „*Metodologie, a w konsekwencji rozwój oprogramowania, pozostają wciąż daleko w tyle za szybko rozwijającymi się rynkami energii. W konsekwencji w wielu krajach regulacje rynkowe musiały zostać dostosowane do aktualnie istniejących systemów rozdziału obciążeń*”.

Próbie rozwiązania problemu doboru składu jednostek wytwórczych na Systemowym Ofertowym REE (model tego rynku funkcjonował w Polsce do 1999 r. i został zastąpiony modelem Systemowego Optymalizująco-Bilansującego REE, matematyczny model tego rynku zamieszczono w [Jur99]) podjęto w [Kal00] i [Wal99]. Złożoność tego silnie nieliniowego problemu optymalizacji dyskretnej, nie pozwala na użycie uniwersalnych technik optymalizacji. Autorzy stosują podejście przybliżone, polegające na głębokiej analizie

problemu i użyciu elementarnych metod optymalizacyjnych. Zaproponowany algorytm pełni rolę systemu wspomagania decyzji i umożliwia znalezienie dopuszczalnych rozwiązań w krótkim czasie.

Dwa algorytmy rozdziału obciążenia stosowane w warunkach rynkowych zaprezentowano w [Mie00]: heurystyczny algorytm „obierania cebuli” stosowany w Australii oraz algorytm programowania liniowego rozwinięty dla rynku nowozelandzkiego. Ten drugi algorytm umożliwia stosunkowo proste wprowadzanie ograniczeń, ale wymaga linearyzacji strat sieciowych i równań opisujących przepustowość sieci przesyłowych, co może mieć duży wpływ na rozdział obciążenia.

O celowości i konieczności wprowadzania skuteczniejszych metod optymalizacyjnych na REE świadczy rosnące niezadowolenie wytwórców, którzy obserwują w ostatnim czasie (po wdrożeniu pod koniec 2001 r. godzinowo – dobowego rynku bilansującego) wzrost kosztów produkcji spowodowany mniejszym obciążaniem bloków, zwiększeniem liczby odstawień oraz dużymi i szybkimi zmianami obciążenia bloków w ciągu doby [Cis02], [Kon02].

3.1. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ Z WYKORZYSTANIEM KONWENCJONALNYCH METOD OPTYMALIZACJI

Metoda ERO według równych przyrostów względnych kosztów zmiennych została wyprowadzona dla ciągłych i wypukłych funkcji kosztów oraz dla ograniczeń równościowych. Uwzględnienie dodatkowych ograniczeń wymaga rozbudowania definicji lagranżianu o składniki będące iloczynami mnożników Lagrange’a (dla warunków równościowych $g_l(\mathbf{x}) = 0$) bądź mnożników Kuhna-Tuckera (dla warunków nierównościowych $h_k(\mathbf{x}) \leq 0$) oraz lewych stron równań i nierówności warunków ograniczających:

$$H_1(\mathbf{x}) = F(\mathbf{x}) + \sum_{l \in L} \lambda_l g_l(\mathbf{x}) + \sum_{k \in K} \mu_k h_k(\mathbf{x}) \quad (3.1)$$

gdzie: $F(\mathbf{x})$ – koszt zdefiniowany jak we wzorze (2.2) lub zależny także od innych zmiennych sterujących \mathbf{x} ; L – zbiór i liczba ograniczeń równościowych; K – zbiór i liczba ograniczeń nierównościowych; λ – mnożnik Lagrange’a; μ – mnożnik Kuhna-Tuckera; $g_l(\mathbf{x})$ – lewa strona l -tego warunku ograniczającego równościowego; $h_k(\mathbf{x})$ – lewa strona k -tego warunku ograniczającego nierównościowego.

Do rozwiązania tak rozbudowanego zadania stosuje się programowanie kwadratowe, jeśli pierwotna funkcja kosztu $F(\mathbf{x})$ jest kwadratowa, a ograniczenia są liniowe lub programowanie wypukłe, jeśli pierwotna funkcja kosztu $F(\mathbf{x})$ jest wypukła, a ograniczenia wyznaczają wypukły zbiór zmiennych [Ber86a]. Dokonując uproszczeń zadanie można sprowadzić do programowania liniowego i rozwiązać metodą simpleks. Algorytm ERO oparty na twierdzeniu Kuhna-Tuckera przedstawiono w [Ber86b]. Równania optymalizacji

otrzymuje się z przyrównania do zera pochodnych cząstkowych lagranżianu, przy czym w kolejnych krokach algorytmu zbiór aktywnych ograniczeń nierównościowych zmienia się.

W [Ber86a] i [Zdu79] podano model ERO z uwzględnieniem rozptyłów mocy. W wyniku obliczeń rozptyłów mocy określa się moduły i argumenty napięć we wszystkich węzłach sieci. Zadaniem jest zmiana mocy czynnych elektrowni oraz przekładni transformatorów w taki sposób, aby uzyskać maksymalną redukcję kosztów wytwarzania, przy spełnieniu wszystkich ograniczeń technicznych. Wskaźnikiem jakości jest sumaryczny przyrost godzinowych kosztów paliwa związany ze zmianami mocy w węzłach wytwórczych:

$$F(\mathbf{x}) = \sum_{i=1}^E \Delta K_{zi} = \sum_{i=1}^E \left[\varepsilon_{ki}(P_{ni0}) + 0,5 \frac{d\varepsilon_{ki}}{dP_{ni}} \Delta P_{ni} \right] \Delta P_{ni} \quad (3.2)$$

gdzie: E – liczba węzłów elektrownianych; ε_{ki} – przyrost względny kosztów i -tej elektrowni; P_{ni0} – wyjściowa moc czynna w i -tym węźle elektrownianym; ΔP_{ni} – przyrost mocy w i -tym węźle elektrownianym.

Wektor zmiennych stanu minimalizujący wskaźnik jakości (3.2) ustala się określając punkt siodłowy lagranżianu (3.1). Zbiór ograniczeń jest opisany nierównościami wynikającymi z warunków technicznych poprawnej pracy elementów systemu oraz równaniami bilansów mocy. Algorytm rozwiązania tego zadania podano w [Ber77]. Jako metodę numeryczną rozwiązania układu równań optymalizacji obrano metodę skończoną uporządkowanej eliminacji Gaussa. Wykonano wielokrotne obliczenia dla krajowego SEE 220 kV i 400 kV. Sieć zawierała ponad 60 węzłów i 90 linii. ERO było objętych 50 elektrowni pracujących na 20 węzłach wytwórczych. Czas obliczeń jednego wariantu (jednej godziny charakterystycznej) wynosił ok. trzy minuty.

Innym przykładem wykorzystania twierdzenia Kuhna-Tuckera do określania ERO mocy czynnej i biernej pomiędzy elektrownie oraz optymalnych poziomów napięć i przekładni transformatorów sprzęgłowych w SEE jest oryginalna metoda opisana w pracy [Szo76]. Warunki optimum przedstawione są w postaci równań dwóch rozptyłów mocy: rzeczywistego i fikcyjnego, zwanego quasi-rozptywem. Oba rozptywy wyznacza się na przemian, korygując za każdym razem zmienne niezależne (wytwarzane moce czynne i bierne oraz przekładnie transformatorów). Wyznaczenie quasi-rozptywu, spełniającego określone w modelu wymagania, równoznaczne jest z wyznaczeniem optymalnego rzeczywistego rozptywu mocy. Przedstawiona metoda jest uogólnieniem metody optymalizacji poziomów napięć w SEE przedstawionej przez autora m.in. w [Szo74]. Funkcja kosztu obejmuje koszty paliwa zużywanego w elektrowniach w jednej godzinie (optymalizacja chwilowa). Moduły i kąty fazowe wektorów quasi-napięć oraz quasi-moce czynne i bierne w węzłach są określonymi przekształceniami odpowiednich wielkości rzeczywistych. Warunki minimum funkcji kosztu, w postaci równań dwóch rozptyłów mocy, otrzymuje się przez odpowiednie przekształcenie warunków w postaci klasycznej (sformułowanych na podstawie twierdzenia

Kuhna-Tuckera) i uwzględnienie związków przekształcających wielkości rzeczywiste na quasi-wielkości.

W [Che98] zaproponowano metodę agregacji ograniczeń nierównościowych w jednym zastępczym ograniczeniu. Pozwala to zredukować wymiar problemu i poprawić zbieżność algorytmu. Zwykle liczba ograniczeń nierównościowych jest dużo większa od równościowych. Przykładowo w systemie z 200 węzłami, 300 gałęziami i 25 generatorami występuje 400 ograniczeń równościowych i ok. 1700 ograniczeń nierównościowych. Zastępcze ograniczenie nierównościowe, które autorzy wyprowadzają korzystając z zasady maksymalnej entropii (*maximum entropy principle*), ma postać:

$$T \ln \sum_{k \in K} \exp\left(\frac{h_k(\mathbf{x})}{T}\right) \leq 0 \quad (3.3)$$

gdzie: T – temperatura (parametr kontrolny).

Po skonstruowaniu lagranżianu zadanie rozwiązuje się metodą Newtona. Liczba mnożników w lagranżianie zostaje zredukowana z $L+K$ do $L+1$.

Oryginalną metodę przeszukiwania przestrzeni rozwiązań (*reduced complexity bundle method*), konkurencyjną do metod gradientowych, w zastosowaniu do rozwiązania lagranżianu (3.1) opisano w [Luh98]. Metoda ta jest szybciej zbieżna od metod gradientowych, nie występuje w niej zjawisko zygzakowatej trajektorii (*zigzag phenomenon*) i może być użyta do nieróżniczkowalnych funkcji kosztów.

Drugą grupę metod konwencjonalnych ERO stanowią metody sprowadzające zadanie do zadania minimalizacji nieliniowej z ograniczeniami równościowymi [Sob84], [Kre96]. Ograniczenia nierównościowe włącza się do funkcji kosztu w postaci kary za przekroczenie ograniczeń:

$$F_k(\mathbf{x}) = F(\mathbf{x}) + \sum_{k \in K} \gamma_k h_k^2(\mathbf{x}) \quad (3.4)$$

gdzie: γ_k – zmienne binarne równe dużym wartościom dla ograniczeń przekroczonych lub 0 dla ograniczeń spełnionych.

Następnie konstruuje się lagranżian postaci:

$$H_2(\mathbf{x}) = F_k(\mathbf{x}) + \sum_{l \in L} \lambda_l g_l(\mathbf{x}) \quad (3.5)$$

Z przyrównania do zera pochodnych funkcji Lagrange’a względem wektora stanu (napięć węzłowych), wektora sterowań (mocy czynnych generowanych, regulowanych modułów napięć oraz przekładni transformatorów) i wektora mnożników λ_l , otrzymuje się rozwiązanie. Wadą metody jest konieczność określenia a priori współczynników γ_k , które powinny mieć

praktyczne uzasadnienie. W obliczeniach praktycznych często dopuszcza się naruszenie przez rozwiązanie optymalne ograniczeń napięciowych i prądowych [Kre96]. W [Cos00] do rozwiązania tak zdefiniowanego zadania optymalnego rozptywu mocy stosuje się algorytm Newtona. Metoda ta wykazuje dobre działanie w porównaniu z metodami konkurencyjnymi, pozwala osiągnąć lepsze rezultaty w znacznie krótszym czasie (zadanie ERO dla 118 JW rozwiązano w czasie 12 s).

Trzecia grupa metod konwencjonalnych polega na sprowadzeniu zadania ERO do zadania bez ograniczeń przez utworzenie następującej funkcji kosztu [Sob84], [Ber86b], [Kre96]:

$$H_3(\mathbf{x}) = F(\mathbf{x}) + r_j \left[\sum_{l \in L} \kappa_{gl} g_l^2(\mathbf{x}) + \sum_{k \in K} \kappa_{hk} h_k^2(\mathbf{x}) \right] \quad (3.6)$$

gdzie: r_j – współczynnik optymalizacji w j -tym kroku optymalizacyjnym; κ_{gl} – współczynnik kary za przekroczenie l -tego ograniczenia równościowego; κ_{hk} – współczynnik kary za przekroczenie k -tego ograniczenia nierównościowego.

Rozwiązanie polega na wyznaczeniu minimum przy ustalonym współczynniku r_j , a następnie zwiększeniu tego współczynnika $r_{j+1} > r_j$ i powtórzeniu obliczeń, aż do uzyskania dwóch dostatecznie bliskich rozwiązań. Wadą metody jest to, że ze względu na szybki wzrost wartości funkcji kary zwiększa się zwykle nakład obliczeń. Składniki związane z ograniczeniami nierównościowymi występują tylko wtedy, gdy dane ograniczenie jest przekroczone, w przeciwnym razie są równe zero. Minimum funkcji (3.6) może być znalezione dowolną metodą minimalizacji funkcji bez ograniczeń – gradientową bądź bezpośrednią (bezgradientową). Po aproksymacji przyrostu funkcji kary w otoczeniu punktu \mathbf{x}^k funkcją kwadratową, do znalezienia minimum funkcji (3.6) stosowany bywa algorytm Newtona. Algorytm ten wymaga ściślej wypukłości funkcji kosztu.

W [Iri98] konstruuje się funkcje Lagrange’a z logarytmicznymi składnikami karnymi oraz ze sztucznymi zmiennymi, których celem jest sprowadzenie rozwiązania początkowego do przestrzeni dopuszczalnej. Dopuszczalnego punktu początkowego wymaga metoda punktu wewnętrznego (*interior point method*), używana do doboru parametrów składników karnych. Metoda ta wywodzi się z algorytmu Karmarkara przystosowanego dla programowania liniowego [Kar84], [Cho95]. Zadanie rozwiązuje się iteracyjnie metodą Newtona. Autorzy uwzględnili w obliczeniach dodatkowe ograniczenia nierównościowe związane z przepustowością sieci (*line flow limits*), rezerwą wirującą (*reserve constraints*) i z szybkością dociążania i odciążania JW (*ramp rate limits*). Podobną metodę optymalizacji rozptywu mocy opisano w [Wei98]. W [AlA98] do standardowej funkcji Lagrange’a dodaje się kwadratowe składniki karne związane z ograniczeniami bilansu mocy, rezerwy wirującej i emisji zanieczyszczeń.

Aproksymacja liniowa i odcinkowo liniowa charakterystyk kosztowych jednostek pozwala zdefiniować zadanie ERO w kategoriach programowania liniowego. Zadanie rozwiązuje się najczęściej metodą simpleks. Liczba iteracji algorytmu i czas obliczeń zależy

od odległości rozwiązania początkowego od optymalnego. Przykłady zastosowania programowania liniowego do zagadnienia ERO można znaleźć w [Wan94].

W [Hua94] zadanie ERO z wieloma ograniczeniami rozwiązywano dwuetapowo. W etapie pierwszym, metodą równych przyrostów względnych, znajdowano rozwiązanie zadania uproszczonego – z pominięciem ograniczeń z wyjątkiem bilansu mocy i dopuszczalnych zakresów pracy jednostek. W drugim etapie linearyzowano zadanie, włączano do niego wszystkie ograniczenia i rozwiązywano je metodą simpleks, startując od punktu znalezionego w etapie pierwszym (bliskiego optymalnemu). Pozwalało to w istotny sposób zmniejszyć czas obliczeń (od 2 do 23 razy) oraz zredukować liczbę iteracji metody simpleks (z $8 \div 54$ do $2 \div 8$) bez utraty jakości wyniku.

Jak zauważono w [Fan98], linearyzacja zadania może powodować problemy ze zbieżnością do rozwiązania optymalnego. Autorzy tej publikacji zadanie ERO rozwiązują techniką programowania kwadratowego (*goal programming*). Dwie iteracyjne metody rozwiązania zadania ERO zdefiniowanego w kategoriach programowania kwadratowego podano w [Dem98]. Metody testowano na dużym systemie elektroenergetycznym; zadanie obejmowało prawie 12 tys. zmiennych i 22 tys. ograniczeń. W [Gra00] ERO jako zadanie programowania kwadratowego rozwiązuje się metodą Goldfarba – Idnaniego.

Duże problemy optymalizacji liniowej poddaje się często dekompozycji na podproblemy, które rozwiązuje się niezależnie. Takie podejście zastosowano w [Wai81], gdzie zlinearyzowane zadanie rozdziału obciążeń zdekomponowano metodą Dantzigą – Wolfa. Pozwoliło to znacznie skrócić czas obliczeń.

W pracy [Mom94] zaprezentowano nową metodę obliczeniową rozwiązywania problemów zdefiniowanych w kategoriach programowania liniowego i kwadratowego (*extended quadratic interior point method*), za pomocą której rozwiązano zadanie ERO. Proponowana metoda, która jest rozszerzeniem algorytmu Karmarkara [Kar84], pozwalała uzyskać rezultaty w czasie krótszym od konkurencyjnej metody simpleks, przy czym liczba iteracji algorytmu nie zależała od rozmiarów systemu (liczby węzłów i generatorów).

Prostą metodę ERO (*merit order method*), która pozwala ominąć wymaganie wypukłości i ciągłości charakterystyk kosztowych JW opisano w [Ong99]. Polega ona na sekwencyjnym dociążaniu (odciążaniu) JW o najniższych (najwyższych) przyrostach względnych w aktualnych punktach pracy, do momentu spełnienia bilansu mocy.

W pracach [Kot71] i [Kot72] przedstawiono probabilistyczny model ERO, w którym obciążenie SEE oraz moc dyspozycyjna bloków przeznaczonych do jego pokrycia są zmiennymi losowymi. Poszukuje się średniego obciążenia każdego bloku, które jest funkcją zmiennych losowych. Wprowadzono zmienną losową R , która jest różnicą między mocą wytwarzaną przez bloki pracujące przy przyroście względnym równym przyrostowi systemu i obciążeniem systemu. Dystrybuanta zmiennej R , obliczanej dla różnych wartości przyrostu względnego, determinuje prawdopodobieństwo pracy bloków przy określonych obciążeniach.

3.2. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ Z WYKORZYSTANIEM METOD SZTUCZNEJ INTELIGENCJI

W ostatnich latach coraz częściej do rozwiązania problemów optymalizacji pracy SEE sięga się po metody sztucznej inteligencji: systemy eksperckie, sztuczne sieci neuronowe, logikę rozmytą, algorytmy ewolucyjne, symulowane wyżarzanie i inne. W wielu przypadkach metody te łączą się z konwencjonalnymi. Przegląd zastosowań metod sztucznej inteligencji do problemów z dziedziny systemów elektroenergetycznych można znaleźć w [Res96] i [Zie98].

Spośród szerokiej gamy sieci neuronowych do optymalizacji szczególnie przydatne są sieci ze sprzężeniem zwrotnym – najczęściej sieci Hopfielda. Sieć rekurencyjna dąży w kolejnych stanach do minimalizacji tzw. funkcji energetycznej, która posiada postać formy kwadratowej [Żur96]. Wartość funkcji energetycznej zależy od zewnętrznych i wewnętrznych pobudeń neuronów oraz parametrów sieci: współczynników wagowych i progów. Po osiągnięciu stanu równowagi (atraktora) na wyjściach sieci pojawia się rozwiązanie minimalizujące funkcję energetyczną. W odniesieniu do problemu ERO funkcja energetyczna $E(\mathbf{x})$ zawiera składnik kosztów wytwarzania $F(\mathbf{x})$ i składnik karny $f_K(\mathbf{x})$ związany z ograniczeniami:

$$E(\mathbf{x}) = \frac{A}{2} F(\mathbf{x}) + \frac{B}{2} f_K^2(\mathbf{x}) \quad (3.7)$$

gdzie: A , B – parametry; $f_K(\mathbf{x})$ – składnik kary definiowany zależnie od zadania, np.

$$f_K(\mathbf{x}) = \sum_{i=1}^N P_{ni} - P_z - \Delta P_s, \text{ przy uwzględnieniu tylko ograniczenia bilansu mocy.}$$

Sieć Hopfielda jest wrażliwa na minima lokalne funkcji energetycznej, wymaga zwykle dużej liczby iteracji (rzędu tysięcy) w dynamicznym procesie minimalizacji i może osiadać w atraktorach periodycznych.

Zastosowanie sieci Hopfielda do ERO z uwzględnieniem ograniczeń przepustowości linii przedstawiono w [Yal98] i [Yal01]. Ograniczenia nierównościowe konwertowano na równościowe i włączono do funkcji energetycznej. Wagi i progi neuronów wyznaczano na podstawie parametrów funkcji kosztu i ograniczeń, co miało ukierunkowywać proces przeszukiwania do obszaru dopuszczalnego. Liczba neuronów w sieci równa była sumie liczby JW i liczby ograniczeń nierównościowych. Osiągnięto wyniki niewiele gorsze od klasycznej metody programowania kwadratowego, przy znacznie krótszym czasie działania algorytmu.

W [Fuk94] opisano zastosowanie do ERO tzw. maszyny Gaussa – rekurencyjnej sieci neuronowej. Równania różniczkowe określające zmianę stanu neuronów w maszynie Gaussa mają postać równań sieci Hopfielda, do których dodaje się losowy szum o rozkładzie Gaussa. Pozwala to stłumić zbieżność sieci do lokalnego optimum. Zastosowano ciągły model sieci z

sigmoidalnymi funkcjami aktywacji. Ograniczenia zakresów zmienności obciążeń jednostek włączono do funkcji aktywacji neuronów. Struktura sieci i organizacja obliczeń pozwalała na implementację równoległą na transputerze. Rezultaty symulacji wskazują na szybszą, w stosunku do programowania kwadratowego, zbieżność proponowanego modelu i jego większą skuteczność. Zaobserwowano, że czas obliczeń nieznacznie wzrasta ze wzrostem rozmiarów zadania, podczas gdy w programowaniu kwadratowym czas ten wzrasta eksponentalnie.

Funkcję energetyczną w podobny sposób zdefiniowano w [Lee98]. W celu przyspieszenia zbieżności sieci Hopfielda i uniknięcia przejściowych oscylacji sieci zaproponowano adaptacyjny współczynnik uczenia i wprowadzono momentum.

Oryginalną architekturę rekurencyjnej sieci neuronowej (*lagrangian neural network*) do zadań zdefiniowanych w kategoriach programowania kwadratowego (z kawałkami kwadratowymi funkcjami kosztów) i nieliniowymi ograniczeniami zaproponowano w [Lee02]. Odstępstwo od warunku wypukłości funkcji kosztu umożliwia wprowadzenie bardziej realistycznych charakterystyk kosztowych JW, uwzględniających punkty zamykania zaworów regulacyjnych, które zakłócają charakterystykę energetyczną turbiny [Jan92]. Sieć ma strukturę dwuwarstwową: pierwsza warstwa (*control layer*) przetwarza ograniczenia, druga (*computing layer*) – wylicza zmienne decyzyjne. Autorzy zauważyli, że działanie sieci cechuje niewielka wrażliwość na współczynnik uczenia i punkt startowy oraz szybka, stabilna zbieżność.

Przykład zastosowania sieci o radialnych funkcjach bazowych (*radial basis function neural network* – RBF) do optymalizacji rozdziału obciążeń można znaleźć w [Ara02]. Sieć realizuje odwzorowanie wartości zapotrzebowania na przyrost względny kosztu zmiennego. Przyrost ten jest używany w drugiej fazie algorytmu do rozdziału obciążeń na generatory prostą metodą iteracyjną. Wadą takiego podejścia jest to, że zestaw jednostek brany pod uwagę w obliczeniach musi być stały i niezmienny (dla różnych zestawów otrzymuje się różne przyrosty względne przy jednakowym zapotrzebowaniu, co prowadzi do niejednoznaczności odwzorowania).

Teorię zbiorów rozmytych w dziedzinie optymalizacji pracy SEE stosuje się w celu reprezentacji niepewnej i nieprecyzyjnej wiedzy, np. na temat obciążenia systemu. Metody rozmyte pozwalają wykorzystać informacje lingwistyczne, operujące pojęciami opisowymi. Wielkościom lingwistycznym przypisuje się zmienne numeryczne, opisane pewnymi funkcjami (tzw. funkcjami przynależności). Przegląd aplikacji teorii zbiorów rozmytych do zagadnień związanych z planowaniem i sterowaniem systemu elektroenergetycznego można znaleźć w [Sar96] i [Mie98].

W [Lia94a] analizuje się optymalizację pracy zespołu elektrowni ciepłych i wodnych w warunkach niepewności zapotrzebowania i wielkości wpływów wody do zbiorników. Koszty generacji, krzywą zapotrzebowania i wpływy do zbiorników modeluje się za pomocą zbiorów rozmytych. Jednostki ciepłe w tej metodzie zostały zagregowane do jednej jednostki opisanej zastępczą funkcją kosztu, aproksymowaną odcinkami linii prostej. Do minimalizacji kosztów generacji stosuje się programowanie liniowe w wersji rozmytej (*fuzzy*

linear programming) – funkcja kosztu i ograniczenia są rozmyte. Rozmyta funkcja kosztu scharakteryzowana jest zbiorem rozmytym zależnym od całkowitego kosztu generacji jednostek ciepłych. Błąd prognozy zapotrzebowania i wpływy wody do zbiorników określa się trójkątnymi funkcjami przynależności. Miarą oceny rozwiązań w modelu optymalizacyjnym (programowania liniowego) jest minimalny stopień przynależności do wymienionych trzech typów zbiorów rozmytych (operacja przecięcia). Wersja rozmyta programowania liniowego pozwoliła uzyskać lepsze rezultaty od wersji ostrej.

W [Gua95] wprowadza się ograniczenia w wersji rozmytej: $h_k(\mathbf{x}) \lesssim d$, gdzie \lesssim – relacja rozmyta. Taki zapis warunku ograniczającego oznacza, że rozwiązanie nie przekracza progu d „zbyt dużo”. W kategoriach rozmytych zapisano również warunek minimalizacji funkcji kosztu: $\min_x F(\mathbf{x}) \lesssim c$. Jakość rozwiązania zależy od stopnia przynależności do zbioru rozmytego Z . Stopień ten określa się jako minimum wszystkich funkcji przynależności do rozmytego kosztu i rozmytych ograniczeń. Rozwiązanie osiąga się maksymalizując stopień przynależności do zbioru Z . Kiedy brak jest rozwiązań dopuszczalnych, przy ostrym zdefiniowaniu problemu, takie złagodzenie zadania pozwala znaleźć dobre rozwiązania, nieznacznie przekraczające ograniczenia.

Teorię zbiorów rozmytych do optymalizacji wielokryterialnej wykorzystano w [Hot00]. Określono trzy kryteria optymalizacji: minimalizację kosztów wytwarzania, minimalizację całkowitej emisji zanieczyszczeń (kwadratowa funkcja obciążeń JW) oraz minimalizację przeciążeń w wybranych liniach przesyłowych. Problemem w tak określonym zadaniu jest znalezienie punktu pracy (obciążeń JW) satysfakcjonującego te kryteria (często sprzeczne ze sobą) i spełniającego narzucone ograniczenia. Do wyznaczenia rozwiązań niezdominowanych autorzy proponują interakcyjną metodę rozmytą (*interactive fuzzy satisfying method*). Dla każdej funkcji kryterialnej definiuje się funkcję przynależności, określającą w jakim stopniu zmienne decyzyjne spełniają wymagania funkcji kryterialnej. Aby otrzymać rozwiązania niezdominowane autorzy rozwiązywali problem minimaksowy:

$$\min \{ \max [\mu_{r_q} - \mu_{f_q}(\mathbf{x})], q = 1, 2, \dots, n \} \quad (3.8)$$

gdzie: μ_{r_q} – wartość odniesienia dla q -tej funkcji przynależności; $\mu_{f_q}(\mathbf{x})$ – wartość q -tej funkcji przynależności; \mathbf{x} – zmienne decyzyjne (obciążenia JW).

Algorytm startuje od pewnych zadanych wartości odniesienia μ_{r_q} , dla których problem (3.8) (do jego rozwiązania autorzy stosują sekwencyjne programowanie kwadratowe) zbiega się do rozwiązania \mathbf{x} . Jeśli rozwiązanie nie jest satysfakcjonujące (ocenia je użytkownik programu), heurystycznie koryguje się μ_{r_q} i powtarza obliczenia.

Algorytmy ewolucyjne i symulowane wyżarzanie pozwalają uzyskać rozwiązania bliskie optymalnym w środowiskach nieliniowych i nieciągłych. Metody te nie wymagają pomocniczych informacji o funkcji kosztu i obliczania pochodnych, znajdują akceptowane rozwiązania po eksploracji niewielkiej części przestrzeni poszukiwań. Zadania mogą być

rozwiązywane kompleksowo, bez podziału na podproblemy. Należy jednak nadmienić, że w zadaniach zdefiniowanych w dużych dziedzinach, AE i SW wymagają długiego czasu działania. Wtedy można definiować specyficzne dla zadania operatory przyspieszające zbieżność lub łączyć te techniki z innymi metodami optymalizacyjnymi. Przegląd zastosowań AE do problemów z dziedziny systemów elektroenergetycznych można znaleźć w [Mir98].

Problem ERO rozwiązywany jest w [She96] za pomocą algorytmów genetycznych (AG) wykorzystujących charakterystyki przyrostów względnych strumieni kosztów zmiennych JW. W pierwszym wariantcie proponowanego AG, obciążenia JW kodowane są binarnie. Warunek optimum jest klasyczny – równość przyrostów względnych wszystkich JW. Wprowadza się błąd niezbilansowania Δ_p oraz błąd przyrostów względnych $\Delta_\varepsilon = \sum |\bar{\varepsilon}_k - \varepsilon_{ki}|$, gdzie: ε_{ki} – przyrost względny i -tej jednostki; $\bar{\varepsilon}_k$ – średni przyrost względny wszystkich JW (przy optymalnym rozdziale obciążeń przyrosty te są równe). Funkcja przystosowania (dostosowana do maksymalizacji) ma postać:

$$F_p(\mathbf{x}) = a[1 - \delta_\varepsilon(\mathbf{x})]^c + b[1 - \delta_p(\mathbf{x})]^d \quad (3.9)$$

gdzie: a, b, c, d – parametry funkcji przystosowania; $\delta_\varepsilon, \delta_p$ – względne błędy przyrostów i niezbilansowania obliczane dla każdego osobnika w populacji: $\delta_{\varepsilon(P)} = (\Delta_{\varepsilon(P)} - \Delta_{\varepsilon(P)\min}) / (\Delta_{\varepsilon(P)\max} - \Delta_{\varepsilon(P)\min})$; $\Delta_{\varepsilon(P)\min}, \Delta_{\varepsilon(P)\max}$ – najmniejsze i największe błędy w populacji.

W drugim proponowanym przez autorów [She96] algorytmie koduje się wartość przyrostu względnego, a obciążenia JW odczytuje się dla tego przyrostu z charakterystyk przyrostów względnych. Umożliwia to uproszczenie funkcji przystosowania do postaci $F_p(\mathbf{x}) = 1 / \delta_p(\mathbf{x})$. Maksymalizacja funkcji $F_p(\mathbf{x})$ prowadzi do minimalizacji niezbilansowania. Minimalny koszt rozwiązania jest zapewniony równością przyrostów względnych wszystkich JW. Taka definicja zmiennych (jedna wartość przyrostu względnego zamiast N wartości obciążeń JW) skraca długość ciągów kodowych i upraszcza zadanie. Algorytm przetwarza te ciągi za pomocą krzyżowania jednorodnego i mutacji binarnej (ze zmiennymi prawdopodobieństwami tych operacji) oraz wykorzystuje strategię elitarną.

W [Li98] z metodą wykorzystującą AG porównano klasyczne metody ERO: dociążania do maksimum kolejnych jednostek o najwyższych sprawnościach (*merit order*), równych przyrostów względnych kosztów zmiennych i metodę gradientową (*local hill climber*). Rozważano kilka wariantów ERO „w punkcie”: z ciągłą i wypukłą funkcją kosztu, z nieliniową i niewypukłą funkcją kosztu, bez uwzględniania i z uwzględnianiem strat sieciowych. W algorytmie genetycznym autorzy zastosowali kodowanie binarne, standardowe krzyżowanie i mutację. Ograniczenie związane z bilansem mocy włączono do funkcji przystosowania w postaci składnika karnego. AG we wszystkich testach znajdował rozwiązania bliskie optymalnym, czego nie można powiedzieć o innych metodach.

W [Das99] zaprezentowano nowe podejście do ERO wykorzystujące metodę przeszukiwania stochastycznego (*stochastic search method*) powstałą na bazie AE i SW. Metoda operuje na chromosomach zmiennopozycyjnych kodujących obciążenia JW przeskalowane liniowo na przedział $\langle 0, 1 \rangle$. Algorytm dobiera obciążenia $N-1$ jednostek wytwórczych, traktując obciążenie jednostki N -tej jako zależne od pozostałych (tak, aby spełnić bilans mocy). Rozwiązania niedopuszczalne są eliminowane z populacji. Pary osobników rodzicielskich generują w procesie krzyżowania (heurystycznego) m osobników potomnych. Parametr m podlega adaptacji stosownie do efektywności procesu przeszukiwania. Najlepszy potomek zastępuje rodzica z prawdopodobieństwem wynikającym z rozkładu Boltzmana. Mutacji nie stosuje się. Testy przeprowadzone dla systemów różnej wielkości wykazały, że proponowany algorytm działa lepiej od algorytmów genetycznych, SW, programowania liniowego i metody Newtona.

W [Rze99] porównano cztery metody optymalizacji globalnej: metodę Monte Carlo, metodę pełzającego simpleksu (Nelder – Meada), metodę SW i metodę strategii ewolucyjnej w zastosowaniu do problemu ERO. Algorytm Nelder – Meada charakteryzuje się szybką zbieżnością w przypadku „głębokich dolin”, a dzięki wprowadzeniu losowych zaburzeń funkcji kosztu, ma możliwość ucieczki z minimów lokalnych. Zastosowano strategię ewolucyjną typu $(\mu + \lambda)$ [Ara01], [Mic96a] z krzyżowaniem arytmetycznym. Charakterystyki kosztowe JW aproksymowane były wielomianami lub siecią Kohonena. Obliczenia przeprowadzono dla trzech bloków, na rzeczywistych danych pochodzących z elektrowni. Ograniczenia uwzględniono w postaci czynników karnych. Algorytm uruchamia się sekwencyjnie dla kolejnych chwil (minut). Rozwiązania znajdowane dla chwil t i $t+1$ różniły się nieznacznie pod względem wartości funkcji kosztu, ale występowały istotne różnice obciążeń jednostek, co z technologicznego punktu widzenia jest niewskazane. Aby ograniczyć to zjawisko do funkcji kosztu wprowadzono karę za nieistotną zmianę rozwiązania. Strategie ewolucyjne i SW okazały się nieznacznie szybsze i dokładniejsze od pozostałych metod. Wyznaczony w trakcie symulacji zysk ze stosowania algorytmu ERO wewnątrz badanej elektrowni, w stosunku do oryginalnego sterowania, które jest zadawane dla każdego bloku przez KDM, wynosił ok. 0,5%.

Wielokryterialne zadanie ERO rozwiązywano na pomocą AE w [Shi01]. Stosowano cztery kryteria: minimalizacji kosztów wytwarzania f_1 , minimalizacji strat sieciowych f_2 , minimalizacji emisji zanieczyszczeń f_3 i maksymalizacji bezpieczeństwa pracy SEE f_4 (kryterium to określono jako iloczyn zakresów generacji JW). Po przekształceniach kryterium f_4 również podlegało minimalizacji. Minimalizowano sumę odległości punktów (f_1, f_2, f_3, f_4) od tzw. punktu idealnego $(f_1^*, f_2^*, f_3^*, f_4^*)$, otrzymanego drogą niezależnej optymalizacji poszczególnych kryteriów. Minimalizowane kryterium miało postać:

$$\min \left\{ \sum_{i=1}^4 [f_i^* - f_i(\mathbf{x})]^p \right\}^{1/p}. \text{ Ograniczenia techniczne uwzględniono wprowadzając funkcje}$$

kary. Tak określone zadanie rozwiązano za pomocą AE, kodując zmienne zmiennopozycyjnie i definiując nowy, samoadaptujący się operator mutacji.

Oryginalną metodę ERO wykorzystującą drzewa decyzyjne (*decision trees*) zademonstrowano w [Roa00]. Obiektami podlegającymi klasyfikacji są wektory obciążeń JW, spełniające bilans mocy. Obiekty opisane są jednym atrybutem – całkowitym kosztem generacji. Zdefiniowano dwie klasy: C_1 – obejmującą obiekty o koszcie mniejszym od proggu kosztowego τ i C_2 – obejmującą obiekty o koszcie większym od τ . W kolejnych iteracjach algorytmu generuje się obiekty z dziedziny (zawężającej się) określonej przynależnością do klasy C_1 obiektów w iteracji poprzedniej. Autorzy testowali tę metodę na wypukłej i niewypukłej funkcji kosztu wykazując jej odporność na osiadanie w minimach lokalnych.

Ostatnio pojawiły się prace [Son98], w których do optymalizacyjnego problemu ERO stosuje się algorytm mrówkowy (*ant system*). Algorytm ten, zdefiniowany przez Marco Dorigo w 1992 r., zainspirowany został rzeczywistym zachowaniem się kolonii mrówek i przeznaczony jest głównie do rozwiązywania problemów kombinatorycznych [www5].

W [Abi02] do ERO zastosowano nowy algorytm (*particle swarm optimization*) podobny do ewolucyjnego, wzorowany na zachowaniu zbiorowości organizmów (np. ławicy ryb, stada ptaków). Algorytm przetwarza populację organizmów, które zmieniają swoje położenie nad przestrzenią rozwiązań. Organizm może ignorować swoje własne doświadczenia (wynikające z eksploracji przestrzeni) i dostosować swoje zachowanie do zachowania organizmów znajdujących się w jego sąsiedztwie (*social-only model*) lub kierować się swoimi doświadczeniami, zachowując się jak byt izolowany (*cognition-only model*). Funkcja kosztu zawierała składnik karny związany z odchyłką napięć w węzłach sieci od wartości znamionowych: $\kappa \sum_l |V_l - 1.0|$, gdzie V_l – napięcie w węźle l -tym w jednostkach względnych. Rezultaty obliczeń optymalizacyjnych wykazały efektywność algorytmu i, zdaniem autora, jego przewagę nad metodami klasycznymi i AG.

3.3. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ Z UWZGLĘDNIENIEM WYMAGAŃ OCHRONY ŚRODOWISKA NATURALNEGO

Zaostrzenie wymogów dotyczących gospodarczego wykorzystania środowiska naturalnego i norm emisji zanieczyszczeń skutkuje opracowaniem wielu strategii ERO uwzględniających problemy ochrony środowiska (*environmentally constrained economic dispatch, economic emission load dispatch*). Strategie te należy rozpatrywać w kontekście aktów prawnych regulujących wymagania ochrony środowiska w stosunku do źródeł substancji zanieczyszczających. Problematykę tę podejmowano już w latach siedemdziesiątych konstruując modele minimalizujące całkowitą emisję zanieczyszczeń, bez uwzględnienia kosztów paliwa [Gen71]. W takim przypadku minimalna emisja zachodzi wtedy, gdy jednostki pracują z jednakowym przyrostem względnym emisji $\forall i : dE_i / dP_{ni} = \lambda$, gdzie: E_i – poziom emisji substancji zanieczyszczającej przez i -tą JW. Najczęściej koszty związane z użytkowaniem środowiska włącza się do funkcji kosztu, a dopuszczalne poziomy emisji zanieczyszczeń uwzględnia się w postaci ograniczeń narzuconych na rozwiązanie zadania. Funkcja kosztu przybiera postać:

$$H_4(\mathbf{x}) = w_1 F(\mathbf{x}) + w_2 K_{ez}(\mathbf{x}) \quad (3.10)$$

gdzie: $F(\mathbf{x})$ – koszt wytwarzania zdefiniowany jak we wzorze (3.1); $K_{ez}(\mathbf{x})$ – koszty emisji zanieczyszczeń proporcjonalne do wielkości emisji poszczególnych zanieczyszczeń oraz ich stopnia szkodliwości dla środowiska naturalnego; w_1, w_2 – współczynniki wagowe ($0 \leq w_1, w_2 \leq 1$).

Jeśli $w_1 = 1, w_2 = 0$ mamy do czynienia z ERO w tradycyjnym rozumieniu, jeśli $w_1 = 0, w_2 = 1$ – minimalizacji podlegają wskaźniki emisji zanieczyszczeń, bez względu na koszty wytwarzania (tzw. EKO-ERO).

Ograniczenia emisji mogą mieć postać: $E_{ik}(T) \leq E_{1k\max}(T)$ (warunek narzucony na i -tą jednostkę) lub $\sum_i E_{ik}(T) \leq E_{2k\max}(T)$ (warunek narzucony na grupę jednostek, np. w obrębie elektrowni), gdzie: $E_{ik}(T), E_{1(2)k\max}(T)$ – emisja k -tej substancji zanieczyszczającej przez i -tą jednostkę i jej dopuszczalny poziom w okresie T .

Zwykle zależność $E_{ik} = f(P_{ni})$ aproksymuje się wielomianem drugiego stopnia [Tal94b], [Ram94], [Nan94], [Mba95], przyjmując liniową relację pomiędzy emisją, a ilością spalanego paliwa. W niektórych publikacjach (np. [Tal94a], [Tal94b]) emisja NO_x aproksymowana jest bardziej złożoną funkcją.

Oprócz przedstawionej powyżej strategii włączania kosztów emisji do funkcji kosztu, spotykane są również strategie, w których funkcja kosztu nie obejmuje kosztów związanych z ochroną środowiska, natomiast wymagania związane z ochroną środowiska ujęte są tylko w formie ograniczeń. W tym przypadku można skonstruować funkcję Lagrange'a (3.1) włączając do niej ograniczenia związane z dopuszczalnymi poziomami emisji poszczególnych substancji zanieczyszczających. Zadanie można rozwiązać iteracyjnie, klasyczną metodą równych przyrostów względnych, przyjmując stałe mnożniki μ_k związane z ograniczeniami emisji. W pierwszej iteracji przyjmuje się $\forall k: \mu_k = 0$. Jeśli dla otrzymanego rozwiązania emisje są mniejsze od dopuszczalnych, jest ono optymalne. W przeciwnym przypadku w iteracji $n+1$ koryguje się metodą Newtona mnożniki μ_k , stojące przy przekroczonych ograniczeniach:

$$\mu_k^{n+1} = \mu_k^n - h_k(\mathbf{x}) \left(\frac{\partial h_k(\mathbf{x})}{\partial \mu_k^n} \right)^{-1} \quad (3.11)$$

gdzie: $h_k(\mathbf{x}) = \sum_i E_{ik}(T) - E_{2k\max}(T)$.

Po każdej korekcie dokonuje się ERO dla nowego zestawu mnożników μ_k . Procedura kończy działanie w momencie, gdy wszystkie ograniczenia poziomów emisji są zachowane. Szczegółowy algorytm zamieszczono w [ElK94a] i [ElK94b].

W pracy [Tal94a] analizowano koszty paliwa oraz wielkości emisji NO_x w zależności od doboru współczynnika w_1 we wzorze (3.10), przy czym przyjęto $0 \leq w_1, w_2 \leq 1$ oraz $w_2 = (1 - w_1)$. Dla systemu złożonego ze 131 jednostek i zadania ERO „w punkcie” uzyskano redukcję emisji NO_x o 20% przy wzroście kosztów paliwa o 53% (dla $w_1 = 0$), ale redukcja emisji o 10% wywoływała zmianę kosztów paliwa jedynie o 0,2% (dla $w_1 = 0,7$). Zależność funkcyjna kosztów wytwarzania od kosztów emisji miała postać zbliżoną do hiperbolicznej.

Algorytm, który minimalizuje koszty paliwa i emisję SO_2 w horyzoncie rocznym, zaproponowany w [Hu94], złożony jest z dwóch pętli. W pętli wewnętrznej obliczane są średnie obciążenia jednostek minimalizujące funkcję kosztu postaci (3.10) przy ustalonych współczynnikach w_1 i w_2 . Korzysta się tu z funkcji Lagrange’a utworzonej z funkcji celu i warunku bilansu mocy. Mnożniki Lagrange’a wyznaczone są iteracyjnie (*lambda iteration searching*). Jeśli całkowita emisja SO_2 została przekroczona, współczynniki w_1 i w_2 są korygowane w pętli zewnętrznej. Korekta polega na zwiększeniu wagi składnika kosztów emisji $\text{SO}_2 - w_2$ i zmniejszeniu wagi w_1 o małą wartość. Dla nowych wartości współczynników dokonywany jest ponownie rozdział obciążeń w pętli wewnętrznej. Obliczenia mogą być przerwane mimo niespełnienia warunku dopuszczalnej emisji, jeśli redukcja emisji uzyskana w dwóch kolejnych cyklach obliczeń powoduje zbyt duży wzrost kosztów paliwa. Algorytm uruchamiany jest kolejno na czterech poziomach: rocznym, miesięcznym, dobowym i godzinowym.

Wśród publikacji dotyczących tematyki ERO z uwzględnieniem emisji zanieczyszczeń można wymienić: [Ram94], gdzie porównano działanie sześciu algorytmów rozwiązania tego zadania, [Tal94b], gdzie dokonano podsumowania różnych strategii podejścia do zagadnienia (m. in. strategię minimalizacji stężenia zanieczyszczeń gleby, strategię uwzględniającą rozkład prawdopodobieństwa emisji, strategię uwzględniającą wpływ umów poolowych na koszty produkcji i emisji), [Nan94], gdzie w modelu uwzględniono straty i ograniczenia sieciowe i zastosowano metodę Gaussa – Seidla do znalezienia rozwiązania, [Mba95], gdzie problem minimalizacji funkcji (3.10) rozwiązuje się za pomocą pakietu optymalizacyjnego MINOS (programowanie liniowe i nieliniowe, z ograniczeniami i bez ograniczeń).

3.4. DOBÓR SKŁADU JEDNOSTEK WYTWÓRCZYCH

Zestaw jednostek wytwórczych najczęściej planuje się na okres kolejnej doby, rzadziej na okres tygodnia lub dziesięciu dni z korektą codobową [Kož94]. Ten sposób stosuje większość z 37 ankietowanych przedsiębiorstw elektroenergetycznych w Europie, Australii, Ameryce i Azji [Wor85]. Okres optymalizacji dzielony jest na przedziały godzinowe, rzadziej pół-, ćwierć-, sześcio- lub dwunastogodzinne.

Do optymalizacji składu JW stosowano wiele różnych metod, które można podzielić na trzy kategorie [She94a], [Sen98], [Man98]:

1. Metody heurystyczne (wiele z nich jest opartych na liście priorytetowej (*priority list*)),
2. Klasyczne metody optymalizacji: programowanie dynamiczne, metoda relaksacji Lagrange’a, metoda podziałów i ograniczeń (*branch-and-bound method*), programowanie

liniowe, programowanie całkowitoliczbowe, programowanie sieciowe (*network programming*) i inne.

3. Metody sztucznej inteligencji: systemy eksperckie, sztuczne sieci neuronowe, algorytmy ewolucyjne, symulowane wyżarzanie i inne.

Naturalną metodą rozwiązania zadania DSJW jest rozpatrzenie wszystkich możliwych kombinacji jednostek i wybór tej kombinacji, dla której koszty są najmniejsze. Postępowanie takie zawodzi w praktyce przy dużej liczbie jednostek ze względu na ogromną liczbę kombinacji i związany z tym długi czas obliczeń. Dla N jednostek i horyzontu optymalizacji równego T godzin, liczba możliwych kombinacji, bez uwzględnienia ograniczeń, wynosi:

$$\sum_{k=1}^{NT} \frac{(NT)!}{k!(NT-k)!} = 2^{NT} - 1, \text{ co dla } N = 10 \text{ i } T = 24 \text{ h daje liczbę rzędu } 10^{72}.$$

Jedną z najwcześniej stosowanych i najprostszych metod DSJW i ERO była metoda oparta na uporządkowanej wg wskaźników ekonomicznych liście jednostek wytwórczych (*priority list, priority order methods*) [Pan81]. Jako wskaźnik ekonomicznej pracy jednostki przyjmowany był np. koszt jednostkowy wytwarzania przy pełnym obciążeniu. Proces doboru JW zachodzi dla każdej chwili okresu optymalizacji. Jeśli obciążenie systemu ulega zmianie i przekracza zdolności wytwórcze załączonych do ruchu jednostek, do załączenia wybiera się kolejną na liście JW. Podobnie przy zmniejszaniu się obciążenia systemu, odstawia się jednostkę ostatnio załączoną (o najgorszym wskaźniku ekonomicznym). Momenty załączenia i odstawienia jednostki następują przy takim samym poziomie obciążenia SEE. Zawsze w ruchu znajdują się jednostki najbardziej ekonomiczne.

W wielu wcześniejszych pracach z zakresu DSJW (np. [Ker66], [Kł62a], [Kł62b], [Guy71]) stosowano heurystyczną metodę, zwaną w literaturze anglojęzycznej *optimal ordered unit decommitment*, opartą na ogólnym algorytmie przedstawionym poniżej:

- rozważa się przebieg zapotrzebowania pomiędzy sąsiednimi szczytami,
- przyjmuje się wyjściowy skład jednostek spełniający ograniczenia,
- postępując po opadającym zboczach przebiegu zapotrzebowania rozważa się pojedyncze odstawienie każdej jednostki na określony czas postoju, wyznaczając koszty takiego rozwiązania,
- porównując koszty rozwiązań „bez odstawienia” i „z odstawieniem” każdej JW, do odstawienia wybiera się tę jednostkę, dla której osiągnięto największy zysk, przy zachowaniu wszystkich ograniczeń technicznych,
- obliczenia powtarza się iteracyjnie dla tego samego punktu przebiegu zapotrzebowania i składu pomniejszonego o wytypowaną do odstawienia jednostkę, do momentu gdy żadne rozwiązanie nie przynosi zysku,
- przechodzi się do kolejnego punktu na zboczach opadającym przebiegu zapotrzebowania, powtarzając obliczenia dla składu wybranego we wcześniejszym etapie obliczeń.

Technika DSJW opisana w [Guy71] zapewnia minimalne koszty paliwa oraz wymagania niezawodnościowe systemu, określone prawdopodobieństwem, że załączone

jednostki pokryją zapotrzebowanie w każdej chwili okresu optymalizacji. Stopień niezawodności pracy systemu w chwili t określa tzw. funkcja bezpieczeństwa $s(t)$ (*security function*), zależna od kombinacji JW i wartości prognozowanego zapotrzebowania. Algorytm DSJW jest analogiczny do przedstawionego powyżej, przy czym decyzja o odstawieniu jednostki i -tej uzależniona jest od wartości funkcji $s(t)$ po jej odstawieniu na określony czas.

Metoda zaproponowana w [Hap71] pozwala minimalizować koszty w systemie złożonym ze stu jednostek, z uwzględnieniem strat sieciowych (w postaci współczynników karnych) oraz kosztów wymiany mocy z systemami sąsiednimi. Wzięto pod uwagę wiele ograniczeń technicznych: poziom rezerwy i szybkość nabierania mocy przy rozruchu JW, jednoczesny rozruch maksymalnie dwóch JW w jednej elektrowni, minimalne czasy pracy i odstawień JW i inne. Algorytm obliczeniowy złożony jest z dwóch bloków: blok I (*suboptimizer*) pozwala uzyskać rozwiązania dopuszczalne bliskie optymalnym, natomiast blok II (*optimizer*) poszukuje rozwiązań lepszych poprzez modyfikacje rozwiązań znalezionych przez blok I. Zasady DSJW stosowane w bloku I oparte są na szeregu reguł logicznych utrzymujących rozwiązanie w dopuszczalnym obszarze, podobnych do reguł stosowanych w praktyce przez dyspozytorów. Działanie bloku II polega na zmianach trybu pracy jednostek (np. praca przy minimum technicznym zamiast krótkotrwałego odstawienia, pozostawienie JW w postoju zamiast krótkotrwałego załączenia) i analizie kosztów w takich przypadkach. Metoda zaimplementowana w bloku I pozwala uzyskać oszczędności na poziomie 1% kosztów paliwa, a w bloku II dodatkowo 0,1%.

W artykule [Zie68] wprowadzono ograniczenie: jednostki mogą być odstawiane najwyżej dwa razy na dobę, co pozwoliło wyróżnić sześć programów pracy JW. Rozpatruje się stany przynależności bloku i -tego z grupy j -tej (reprezentującej j -ty program) do pozostałych grup, wyprowadzając zależności przedstawiające różnicę kosztów w takich przypadkach. W zależnościach tych uwzględnia się charakterystyki rozpatrywanego bloku oraz przebieg funkcji przyrostu względnego systemu. Ostatecznie blok zalicza się do grupy, dla której osiąga się największe dodatnie zyski.

W [Ayo71] zadanie DSJW, z uwzględnieniem wymagań bezpieczeństwa pracy systemu określonych podobnie jak w [Guy71] funkcją bezpieczeństwa, rozwiązywano trój etapowo: w etapie I wyznacza się rozwiązanie, które minimalizuje koszty pracy jednostek w każdej godzinie rozpatrywanego okresu, w etapie II rozwiązanie jest modyfikowane tak, aby osiągnąć wymaganą wartość funkcji bezpieczeństwa i w etapie III kolejne modyfikacje mają zapewnić minimum kosztu sumarycznego: pracy i rozruchów jednostek. Rozwiązanie w etapie I otrzymuje się metodą programowania dynamicznego.

Probabilistyczny model zadania dobowego planowania wytwarzania oraz metodę jego rozwiązania przedstawiono w [Gła80b]. Na skutek działań czynników losowych w trakcie realizacji planu, parametry zadania różnią się od przyjętych przy planowaniu, a więc wyznaczony wcześniej plan może okazać się nieoptymalny. W takich warunkach dokonywana jest operatywna zmiana obciążeń jednostek z zachowaniem zasady ERO. Możliwość korygowania składu jednostek jest ograniczona ze względu na czas uruchamiania bloków. Analiza statystyczna wykazała, że dla realizujących się warunków, można było

osiągnąć minimum kosztów przy innym składzie jednostek, niż przy wyznaczonym w trakcie planowania. Autorka wprowadza do modelu ERO następujące niezależne zmienne losowe o znanych parametrach rozkładu: zapotrzebowanie mocy, obciążenia elektrowni wodnych, awaryjność bloków oraz losowe czynniki kształtujące zdolności wytwórcze bloków (maksimum i minimum techniczne). Zadanie optymalizacyjne rozwiązywane jest niezależnie dla każdego przedziału czasowego okresu optymalizacji i sprowadza się do wyznaczenia składu bloków, przy którym wartość oczekiwana sumarycznych kosztów obejmujących koszt generacji, zmniejszenie kosztów na skutek awaryjnych ubytków mocy oraz koszt pokrycia strat gospodarczych w wyniku wystąpienia deficytu mocy, jest minimalna.

Celowość uwzględniania czynnika losowego związanego z awaryjnością urządzeń uzasadniano w [Gła80c]. Analiza tego zagadnienia wykazała, że w warunkach krajowych czynnik losowy awaryjności ma istotny wpływ na realizację planów sporządzanych w cyklu dobowym; wykazano ekonomiczną zasadność utrzymywania w ruchu w szczycie wieczornym rezerwy wirującej na poziomie ok. 4% mocy osiągalnej, zamiast 2% przyjmowanych ówczesnie przy planowaniu.

Problem DSJW z uwzględnieniem kontraktów terminowych na sprzedaż energii elektrycznej, zawieranych pomiędzy wytwórcami a firmą przesyłową, podjęto w pracy [Gła95]. Przyjętym kryterium jest tutaj minimalizacja kosztów produkcji energii elektrycznej oraz minimalizacja kosztów kar umownych za niezrealizowanie zagwarantowanej kontraktem minimalnej ilości zakupionej energii. Metoda wykorzystuje zmodyfikowane charakterystyki czasów granicznych, które konstruuje się na podstawie poniższych wzorów (dla odstawiania bloku – (3.12), dla uruchomienia – (3.13)), wprowadzając składnik ρK_{zi} będący ekwiwalentem kar umownych w odniesieniu do godzinowej produkcji energii elektrycznej:

$$[K_{zi}(P_{ni}) - \rho K_{zi}(P_{ni}) - \varepsilon_{ks} P_{ni}] t_{pi} - K_{ri}(t_{pi}) \geq 0 \quad (3.12)$$

$$[\varepsilon_{ks} P_{ni} - K_{zi}(P_{ni}) + \rho K_{zi}(P_{ni})] t_{ri} - K_{ri}(t_{ri}) \geq 0 \quad (3.13)$$

przy czym: ρ – współczynnik udziału w karze umownej za niewykonanie produkcji energii w stosunku do planu.

Wzory na obliczanie czasów granicznych w przypadku odstawienia i rozruchu bloku wyprowadza się z powyższych zależności. Czas graniczny w przypadku odstawienia bloku zagrożonej niewykonaniem kontraktu elektrowni będzie dłuższy (blok odstawiony w dalszej kolejności), a w przypadku uruchomienia – krótszy niż wynikałoby to z klasycznej metody charakterystyk czasów granicznych.

Programowanie dynamiczne w zastosowaniu do DSJW realizowane jest wg następującego algorytmu. Na każdym etapie przeprowadza się obliczenia dla każdej kombinacji współpracujących jednostek k_{pj} ; kombinacje numeruje się od 1 do l_k . Pętla zewnętrzna algorytmu przebiega po kolejnych chwilach (godzinach) okresu optymalizacji T , pętla wewnętrzna – po kolejnych kombinacjach zestawów JW. Dla każdej kombinacji rozdziela się optymalnie obciążenie systemu $P_z(t)$ i oblicza koszty:

$$K_{\Sigma \min}(k_{pj}, t) = \sum_{i \in k_{pj}} K_{zi}(\hat{P}_{ni}) + K_{\Sigma \min}(k_{pj} = L, t-1) + \sum_{j \in R} K_{rj}(t_{pj}) \quad (3.14)$$

gdzie: \hat{P}_{ni} – optymalne obciążenia jednostek kombinacji k_{pj} ; $K_{\Sigma \min}(k_{pj} = L, t-1)$ – optymalny (z punktu widzenia etapu t) koszt znaleziony na etapie $(t-1)$, otrzymany dla kombinacji L ; R – zbiór jednostek, które w optymalnej kombinacji L , znalezionej w etapie $(t-1)$, były wyłączone, a które zostają załączone w bieżącej kombinacji k_{pj} ; $K_{rj}(t_{pj})$ – koszty rozruchu jednostki j -tej po czasie postoju t_{pj} .

Pierwszy składnik równania (3.14) reprezentuje koszt pracy jednostek kombinacji k_{pj} w godzinie t , drugi – sumaryczny koszt pracy i uruchomień jednostek należących do różnych optymalnych kombinacji we wcześniej rozpatrywanych etapach i trzeci – koszt przejścia z kombinacji L do bieżącej kombinacji k_{pj} , będący sumą kosztów rozruchów jednostek załączonych w kombinacji k_{pj} i wyłączonych w kombinacji L . Wynikiem działania tej procedury jest tabela zawierająca minimalne koszty sumaryczne, otrzymane w kolejnych etapach dla każdej kombinacji pracy jednostek:

Godzina \ Kombinacja	1	2	...	T
1	$K_{\Sigma \min}(1, 1)$	$K_{\Sigma \min}(1, 2)$...	$K_{\Sigma \min}(1, T)$
2	$K_{\Sigma \min}(2, 1)$	$K_{\Sigma \min}(2, 2)$...	$K_{\Sigma \min}(2, T)$
...
l_k	$K_{\Sigma \min}(l_k, 1)$	$K_{\Sigma \min}(l_k, 2)$...	$K_{\Sigma \min}(l_k, T)$

W trybie „postępowania wstecz” z ostatniej kolumny tabeli odczytuje się minimalny koszt i kombinację, dla której go otrzymano. Korzystając z informacji o kosztach przejścia rozwiązań z etapu $(T-1)$ do etapu T , znajdujemy optymalną kombinację na etapie $(T-1)$. Poruszając się w ten sposób wstecz do etapu $t=1$, otrzymujemy rozwiązanie optymalne w całym okresie optymalizacji T .

Rozpatrzenie wszystkich możliwych składów jednostek w praktyce może okazać się niewykonalne w czasie rzeczywistym. Zwiększenie wymiaru zadania o 1, tzn. zwiększenie liczby jednostek z N do $(N+1)$, zwiększa dwukrotnie przestrzeń poszukiwań (o 2^N punktów). Do rozwiązania zadania często używa się superkomputerów implementując programowanie dynamiczne w sposób równoległy [Mis94]. Wiele publikacji dotyczy sposobów ograniczania przestrzeni rozwiązań.

W pracy [Pan76] wprowadzono technikę nazwaną *Truncated Dynamic Programming*. Procedurę obliczeniową podzielono na dwie części. W części pierwszej formuje się listę selekcyjną jednostek (*unit selection list*) uporządkowanych wg średnich wartości przyrostów względnych strumieni kosztów paliwa. Określa się minimalną liczbę k jednostek, które pokryją zapotrzebowanie z uwzględnieniem rezerwy wirującej. Wokół jednostki k -tej, licząc

od początku listy, definiuje się zakres poszukiwań – Z_p (*search range*) obejmujący l kolejnych jednostek z listy o rangach mniejszych od k i m kolejnych jednostek o rangach większych od k . Wśród tych jednostek poszukuje się kombinacji zapewniającej najlepsze rozwiązanie, przyjmując, że jednostki o rangach mniejszych od $(k - l)$ posiadają status *must run*. Wartości l i m sterują zasięgiem przeszukiwań przestrzeni rozwiązań. Dla dużych zmian zapotrzebowania w okresie T wymagany jest większy zakres przeszukiwań. Metoda nie zawsze daje rozwiązania optymalne globalnie.

W [Pan81] porównano działanie czterech metod DSJW: jednej opartej na liście priorytetowej (LP) i trzech wykorzystujących programowanie dynamiczne: *Dynamic Programming – Sequential Combination* (DP-SC), *Dynamic Programming – Truncated Combination* (DP-TC) oraz hybrydy DP-SC i DP-TC nazwanej *Dynamic Programming – Sequential/Truncated Combination* (DP-STC). Metoda DP-SC generuje kombinacje w oparciu o listę priorytetową w następujący sposób:

$$C(i) = \begin{cases} \{\emptyset\} & \text{dla } i = 1 \\ \{r_1, r_2, \dots, r_{(i-1)}\} & \text{dla } i = \overline{2, N+1} \end{cases} \quad (3.15)$$

gdzie r_i oznacza rangę jednostki, a $C(i)$ – i -tą kombinację: $C(1)$ – wszystkie jednostki wyłączone, $C(2)$ – jednostka o randze 1 załączona, pozostałe wyłączone, $C(3)$ – jednostki o rangach 1 i 2 załączone pozostałe wyłączone itd. Liczba kombinacji w tym wypadku jest równa $(N + 1)$.

Dla zadania z pięćdziesięcioma dwiema jednostkami metody wykorzystujące programowanie dynamiczne pozwalały uzyskać redukcję kosztów w stosunku do metody opartej na liście priorytetowej o: DP-SC – 7,99%, DP-STC – 8,06%, DP-TC – 10,04%. Czas obliczeń kształtował się następująco: metoda listy priorytetowej – 13 s, DP-SC – 29 s, DP-STC – 114 s, DP-TC – 982 s.

Autorzy [Pan81] analizowali wpływ błędu prognozy zapotrzebowania na oszczędności uzyskane w wyniku zastosowania metody DP-SC. Wyznaczono skład jednostek S_1 dla zapotrzebowania oryginalnego i skład S_2 dla zapotrzebowania zmodyfikowanego (obciążonego błędem). Dla przebiegu zmodyfikowanego wyznaczono koszty przy składzie S_1 i S_2 . Oszczędności otrzymane przy składzie S_2 w stosunku do S_1 wzrastały liniowo ze wzrostem błędu prognozy δ_{p_z} i wyniosły: dla $\delta_{p_z} = 3,5\%$ – 0,22%, dla $\delta_{p_z} = 7,0\%$ – 0,90%, dla $\delta_{p_z} = 10,0\%$ – 1,19%.

Innym przykładem zastosowania metody DP-TC oraz DP-SC jest praca [Wai81], gdzie rozważano zadanie DSJW z wieloma ograniczeniami (min. zapewnienie wymaganej rezerwy mocy, dopuszczalnej szybkości dociążania i odciążania jednostek, minimalnego czasu odstawienia i pracy jednostek). Rozdział obciążeń dla poszczególnych kombinacji z zakresu przeszukiwań Z_p , dokonywany był przy użyciu programowania liniowego, po linearyzacji problemu ERO. Stwierdzono, że metoda DP-TC jest dokładniejsza, choć

znacznie wolniejsza od DP-SC. Istotne znaczenie ma heurystyczna lokalizacja na liście selekcyjnej zakresu poszukiwań i jego rozmiar.

Nową metodę optymalizacji opartą na programowaniu dynamicznym (*constructive dynamic programming* – CDP) do DSJW opisano w [Tra98]. Metoda ta znajduje zastosowanie w zadaniach, w których funkcja kosztu zdefiniowana jest jako odcinkowo liniowa. Różnica pomiędzy klasyczną metodą programowania dynamicznego a CDP polega na tym, że CDP nie wymaga dyskretyzacji zmiennych decyzyjnych. Zamiast tego przestrzeń rozwiązań dzielona jest na regiony o jednakowych przyrostach względnych kosztów zmiennych.

W [Su91] zaprezentowano programowanie dynamiczne w wersji rozmytej (*fuzzy dynamic programming*). Istotą tego podejścia jest potraktowanie prognozowanego zapotrzebowania jako wielkości nieprecyzyjnej i zamodelowanie go za pomocą zbiorów rozmytych. Podobnie, w sposób rozmyty, modeluje się rezerwę wirującą. Dla rozmytej funkcji celu, zapotrzebowania i rezerwy autorzy zdefiniowali zbiory rozmyte i funkcje przynależności. Przecięcie tych trzech zbiorów determinuje jakość rozwiązania. Algorytm był testowany w zadaniu optymalizacji dobowej pracy systemu złożonego z 54 JW. Czas obliczeń był 30 razy krótszy niż wymagany w programowaniu dynamicznym.

Wnioski z praktycznego zastosowania programowania dynamicznego w jednym z amerykańskich przedsiębiorstw elektroenergetycznych można znaleźć w [Le83]. Zadanie optymalizacyjne obejmuje dobór ciepłych jednostek wytwórczych oraz elektrowni wodnych, przy uwzględnieniu wielu ograniczeń technicznych.

Metoda relaksacji Lagrange'a wymaga utworzenia lagranżianu z funkcji kosztu i jej ograniczeń. Problem minimalizacji funkcji Lagrange'a jest dekomponowany na problem nadrzędny (*master problem*) i mniejsze, łatwiejsze do rozwiązania problemy podrzędne (suboptymalizacyjne). Zadanie sprowadza się do problemu dualnego i poszukuje się mnożników Lagrange'a oraz Kuhna-Tuckera maksymalizujących dualną funkcję celu:

$$\max_{\lambda_i(t), \mu_k(t)} \left\{ \min_{P_{ni}(t), \alpha_i(t)} L [P_{ni}(t), \alpha_i(t), \lambda_i(t), \mu_k(t)] \right\} \quad (3.16)$$

gdzie: $\alpha_i(t)$ – funkcja binarna określająca stan i -tej JW w chwili t ; L – funkcja Lagrange'a. Algorytm rozwiązujący tak postawione zadanie operuje na dwóch poziomach: nadrzędnym, w którym aktualizuje się mnożniki $\lambda_i(t)$ i $\mu_k(t)$ oraz podrzędnym, w którym dla stałych mnożników oblicza się obciążenia i stany jednostek minimalizujące lagranżian. Rozwiązanie znalezione na poziomie podrzędnym wykorzystywane jest dalej do korekty mnożników na poziomie nadrzędnym. Ta procedura powtarzana jest do momentu zbiegnięcia się do rozwiązania optymalnego. W [Mer83] problem minimalizacji lagranżianu rozwiązuje się za pomocą programowania dynamicznego, natomiast do problemu maksymalizacji używa się metod gradientowych, które pozwalają wyprowadzić równania na modyfikacje mnożników $\lambda_i(t)$ i $\mu_k(t)$ zapewniające zbieżność algorytmu. Znalezienie rozwiązania problemu

dualnego nie gwarantuje jednak tego, że będzie ono dopuszczalne z powodu niewypukłości funkcji prymalnej (oryginalnej). W metodzie zwanej *augmented lagrangian relaxation*, wprowadza się sztuczne ograniczenia i zmienne, które w postaci kwadratowych funkcji karnych włącza się do funkcji kosztu [She94a]. Pozwala to poprawić wypukłość funkcji kosztu i przyspieszyć zbieżność. W [Ruz98] proponuje się metodę uaktualniania mnożników $\lambda_l(t)$ i $\mu_k(t)$, która ma zapewnić znalezienie rozwiązania problemu prymalnego. Stopień modyfikacji mnożników w tej metodzie zależy od odległości rozwiązania problemu dualnego od prymalnego. W [Duo99] przedstawiono metodę korekty rozwiązań problemów dualnych za pomocą programowania ewolucyjnego.

Jakkolwiek relaksacja Lagrange'a nie gwarantuje rozwiązań optymalnych, uważana jest za jedną z najlepszych metod DSJW w dużych systemach elektroenergetycznych [Duo99]. Porównywana z innymi metodami jest bardziej elastyczna (umożliwia wprowadzenie różnych warunków ograniczających) i odznacza się wyższą efektywnością obliczeniową [Sen98].

W metodzie podziałów i ograniczeń zbiór wszystkich możliwych kombinacji pracy jednostek k_{pj} rozdziela się na pewną liczbę podzbiorów, które w kolejnych iteracjach algorytmu ulegają podziałowi na mniejsze podzbiory itd. Proces ten można zobrazować drzewem rozwiązań, którego każdy wierzchołek odpowiada pewnej kombinacji k_{pj} . Pełne drzewo rozwiązań jest równoznaczne z przeglądem zupełnym. Jeśli dla każdego podzbioru można określić dolną granicę wskaźnika jakości wszystkich kombinacji zawartych w tym podzborze, przegląd może być skrócony. Jeśli dolna granica wskaźnika jakości dla rozpatrywanego podzbioru A jest większa od wyliczonego wcześniej wskaźnika dla innego podzbioru B , cały podzbiór A może być pominięty i nie wymaga rozgałęziania, ponieważ nie zawiera rozwiązania optymalnego. Metoda wymaga osłabienia zadania, co pozwala szacować dolne granice wskaźnika jakości. Dla zadania osłabionego charakterystyki oryginalne kosztów zmiennych jednostek $K_{zi}(P_{ni})$ zastępuje się wypukłymi charakterystykami określonymi w przedziale $0 \leq P_{ni} \leq P_{nmaxi}$ następująco [Ber86b]:

$$K'_{zi}(P_{ni}) = \begin{cases} \frac{K_{zi}(P_{ni}^*)}{P_{ni}^*} P_{ni} & \text{dla } 0 \leq P_{ni} \leq P_{ni}^* \\ K_{zi}(P_{ni}) & \text{dla } P_{ni}^* \leq P_{ni} \leq P_{nmaxi} \end{cases} \quad (3.17)$$

gdzie P_{ni}^* – współrzędna punktu styczności prostej przechodzącej przez punkt $(P_{ni} = 0, K_{zi} = 0)$ z charakterystyką oryginalną $K_{zi}(P_{ni})$.

Zadanie osłabione polega na minimalizacji funkcji $K'_\Sigma = \sum_{i \in C} K'_{zi}(P_{ni})$ z ograniczeniami

$\sum_{i \in C} P_{ni} = P_\Sigma$ i $\forall i \in C : 0 \leq P_{ni} \leq P_{nmaxi}$, gdzie C – zbiór jednostek załączonych (o stanie 1) w

aktualnie rozpatrywanej kombinacji k_{pj} . Zadanie osłabione można rozwiązać metodą równych przyrostów względnych. Wykazano, że rozwiązanie K'_Σ problemu osłabionego może służyć

jako dolna granica funkcji celu dla wszystkich kombinacji k_{pj} . Uwzględnienie kosztów rozruchów i rezerwy wirującej wymaga modyfikacji charakterystyk jednostek (3.17).

Metoda podziałów i ograniczeń porównywana bywa do metody programowania dynamicznego; obie metody pozwalają w sposób systematyczny i inteligentny przeszukiwać przestrzeń dopuszczalnych rozwiązań.

W [Coh83] zastosowano algorytm podziałów i ograniczeń do DSJW, ograniczając rozmiary problemu poprzez przyjęcie założenia, że JW może być tylko raz załączana i raz odstawiana w okresie optymalizacji. Dla każdej JW określa się dwa interwały: A , w którym może nastąpić załączenie jednostki i B , w którym może nastąpić jej odstawienie, przy czym załączenie następuje wcześniej niż odstawienie. Startuje się od interwałów równych (dla okresu optymalizacji $T = 24$ h) $A = [1, 24]$, $B = [1, 24]$. Po rozgałęzieniu drzewa, na drugim poziomie, interwały jednej JW dzielone są na dwie części, co generuje cztery kombinacje interwałów: $([1, 12], [1, 12])$, $([1, 12], [13, 24])$, $([13, 24], [13, 24])$, $([13, 24], [1, 12])$, przy czym ostatnia kombinacja jest niedopuszczalna. Interwały pozostałych jednostek na tym poziomie nie zmieniają się. Na poziomie trzecim następuje rozgałęzienie drzewa (połówkowanie interwałów dla kolejnej JW) z każdego wierzchołka utworzonego na poziomie drugim. W ten sposób na wyższych poziomach drzewa rozwiązań interwały zawężają się, obejmując na poziomie ostatnim tylko jeden punkt.

W [Lau82] zastosowano technikę opartą na algorytmie podziałów i ograniczeń do zadania o dużej skali: 250 jednostek wytwórczych i okres optymalizacji $T = 12$ (12 tys. zmiennych decyzyjnych). W obliczeniach uwzględnia się ograniczenia techniczne JW: czasy rozruchu ze stanu gorącego i zimnego, minimalne czasy pracy i postoju oraz inne. Przy implementacji równoległej czas działania algorytmu jest mniejszy od 30 min. W [Dil78] i [Tak00] problem DSJW zdefiniowano w kategoriach programowania całkowitoliczbowego (*integer programming*) i rozwiązano metodą podziałów i ograniczeń. Metoda pozwala uwzględnić wiele ograniczeń i jest przystosowana do praktycznego zastosowania. W [Hua98] zaproponowano programowanie logiczne (*logic programming*) do rozwiązania problemu DSJW. Algorytm podziałów i ograniczeń używany jest tu w procesie iteracyjnego przeszukiwania przestrzeni rozwiązań w strukturze programowania logicznego. Algorytm zapewnia znalezienie rozwiązania bliskiego optymalnemu w krótkim czasie. Wyniki były porównywalne lub lepsze od konkurencyjnych metod: relaksacji Lagrange'a, programowania dynamicznego i symulowanego wyżarzania.

Programowanie sieciowe wymaga zamodelowania problemu DSJW w kategoriach problemu najkrótszej ścieżki i rozwiązania go odpowiednią techniką optymalizacyjną, np. techniką Dijkstry [Sys93]. Wierzchołki sieci reprezentują kombinacje JW i są powiązane łukami. Każda godzina reprezentuje jeden stan. Wierzchołki należące do jednego stanu połączone są pionowymi łukami; wierzchołki należące do kolejnych stanów ustawione są w kolejności. Z każdym łukiem związany jest koszt (wytwarzania i rozruchu) przejścia z kombinacji i -tej w godzinie t do kombinacji j -tej w godzinie $t+1$. Startując od wierzchołka źródłowego, przeszukuje się węzły kolejnych stanów, zapamiętując najkrótszą ścieżkę (koszt). Jeśli przejście z jednego wierzchołka do drugiego narusza ograniczenia, koszt łuku

łącającego te wierzchołki jest nieskończony. Zastosowanie programowania sieciowego do DSJW opisano szczegółowo w [Zhu95]. Dla ograniczenia liczby wierzchołków rozważa się tylko podzbiór kombinacji. Testując metodę na systemie złożonym z 63 JW i przyjmując horyzont optymalizacji równy 24 h, otrzymano wyniki takie same jak w metodzie DP-TC, lecz w czasie ok. 4,5 razy krótszym.

Systemy eksperckie często wykorzystywane są do korekty parametrów modeli optymalizacyjnych, poprzez wprowadzanie wiedzy pozyskanej od ekspertów. Umożliwiają wprowadzenie ograniczeń, które trudno zaimplementować w innych metodach. Pozwalają też nawiązać dialog dyspozytora z systemem i pomagają zrozumieć drogę dochodzenia do rozwiązania, zwiększając w ten sposób zaufanie do otrzymanego rezultatu.

W [Mok88] przedstawiono system ekspercki w zastosowaniu do analizy i poprawy działania metody programowania dynamicznego. Niezbędne informacje do korekty parametrów podstawowej metody optymalizacji DSJW wprowadzane są przez dyspozytora w fazie pytań zadawanych przez system i dotyczą m.in.: listy priorytetowej, ograniczeń minimalnego czasu pracy i postoju JW, stanów początkowych JW itp. System ekspercki umożliwia wprowadzanie dodatkowych ograniczeń, które są zbyt trudne i kosztowne dla podstawowej metody optymalizacji. Otrzymane rozwiązanie może być dalej korygowane w fazie dialogu dyspozytora z systemem. Podobne podejście tzn. hybrydę systemu eksperckiego i programowania dynamicznego do problemu DSJW zaprezentowano w [Kot95]. W [Pad97] system ekspercki koryguje rozwiązania DSJW otrzymane za pomocą rozmytej sieci neuronowej.

W algorytmach ewolucyjnych przetwarza się zakodowane rozwiązania zadania DSJW. Kodowanie najczęściej jest binarne; ciągi kodowe (chromosomy) wyrażają stany JW w kolejnych chwilach okresu optymalizacji. Pojedynczy punkt w przestrzeni rozwiązań determinuje więc harmonogramy pracy wszystkich JW, w całym okresie optymalizacji T . Ograniczenia narzucone na rozwiązania można włączyć do funkcji kosztu w postaci składników karnych. Na efektywność działania algorytmu istotny wpływ ma sposób kodowania parametrów zadania i definicje operatorów genetycznych. AE należy do metod optymalizacji globalnej i często, aby poprawić jego zdolność przeszukiwania lokalnego, łączy się go z technikami optymalizacji lokalnej. Czas działania AE w zadaniu DSJW jest kwadratową funkcją liczby JW [Kaz96].

Przykład zastosowania algorytmu genetycznego z kodowaniem binarnym jw., selekcją metodą koła ruletki i specjalizowanymi operatorami genetycznymi, zaprezentowano w [Kaz96]. Współczynniki kary w funkcji przystosowania wzrastają liniowo ze wzrostem licznika generacji. Autorzy stosują strategię elitarną i skalowanie funkcji przystosowania. Prawdopodobieństwa krzyżowania i mutacji są zmienne, zależne od efektywności algorytmu. Oprócz krzyżowania wielopunktowego i klasycznej mutacji binarnej autorzy proponują kilka operatorów specjalizowanych. Znaczną poprawę zbieżności zapewnia operator nazwany *swap-window hill-climb operator*. Dla fragmentów chromosomu kodujących harmonogramy dwóch JW określa się „okno czasowe” o długości H godzin. Bity kodujące stany pary JW w tym oknie zamienia się miejscami i oblicza koszty takiego rozwiązania. Okno czasowe

przesuwa się od pierwszego do ostatniego bitu kodującego harmonogramy JW. Zadania testowe (DSJW w okresie $T = 24$ h, dla liczby JW od 10 do 100) rozwiązano proponowanym algorytmem, metodą relaksacji Lagrange'a i programowaniem dynamicznym (tylko dla 10 JW). Dla 10 JW otrzymano rezultaty jednakowe, dla większej liczby JW, we wszystkich przypadkach AG był wyraźnie lepszy od relaksacji Lagrange'a. Różnice kosztów pomiędzy najlepszymi i najgorszymi rozwiązaniami zwróconymi przez AG w 20 próbach wynosiły 0,74% lub mniej. Dla 100 JW obliczenia za pomocą AG trwały ok. 4 h.

W [Das94], celem ograniczenia przestrzeni rozwiązań, zaproponowano prosty AG, sekwencyjnie optymalizujący DSJW dla pojedynczych godzin okresu optymalizacji T . Chromosom reprezentuje stany JW w jednej godzinie. Funkcja przystosowania zawiera człony karne. W pierwszej fazie obliczeń, dla każdej godziny uruchamia się AG i zapamiętuje się n rozwiązań o najmniejszych kosztach. Rozwiązanie optymalne względem całego okresu optymalizacji tworzy się w II fazie algorytmu, zestawiając i analizując wszystkie rozwiązania optymalne z I fazy. Jakość rozwiązania końcowego jest lepsza dla większej liczby n .

W [Duo99] algorytm ewolucyjny wykorzystywany jest do korekty rozwiązań problemu dualnego w metodzie relaksacji Lagrange'a tak, aby optymalizowały one problem primalny. Chromosom jest wektorem zmiennopozycyjnym kodującym obciążenia JW w chwili t . Populacja startowa zawiera rozwiązania problemu dualnego zakłócone losowym szumem. W procesie ewolucyjnym chromosomy potomne tworzy się z rodzicielskich poprzez dodanie do nich wartości losowanej z rozkładu Gaussa (podobnie jak w strategiach ewolucyjnych). Wspomaganie metody relaksacji Lagrange'a algorytmem ewolucyjnym pozwoliło zmniejszyć koszty rozwiązań o ponad 1%. Podobny sposób połączenia relaksacji Lagrange'a z AG pokazano w [Ore97].

W [Won98a] zadanie DSJW z uwzględnieniem (w postaci ograniczeń) emisji zanieczyszczeń rozwiązano za pomocą AE z reprezentacją zmiennopozycyjną obciążeń JW. Obciążenie jednego generatora wyliczane było z równania bilansu mocy, wobec czego warunek bilansu był zawsze spełniony. Populację inicjowano w ten sposób, aby każda JW dotrzymywała ograniczeń emisji. Chromosomy podlegały mutacji poprzez dodanie wartości losowanych z rozkładu Gaussa, przy czym sterowano parametrem tego rozkładu. Krzyżowania nie stosowano. Metodą selekcji był turniej stochastyczny. Wprowadzono technikę przyspieszania zbieżności polegającą na przesuwaniu każdego rozwiązania z populacji w kierunku rozwiązania najlepszego. W [Yur99] do przyspieszenia zbieżności w AE, zdefiniowanym w podobny sposób, stosowano algorytm gradientowy.

Dla generowanych w procesie ewolucyjnym chromosomów, należy określić koszty wytwarzania, czyli wykonać obliczenia ERO, dla każdej chwili okresu optymalizacji. Procedura ERO zajmuje ok. 70% czasu działania algorytmu. AG zaproponowany w [She94b] wymaga obliczeń ERO tylko w procesie inicjalizacji populacji i mutacji (zachodzącej z niewielkim prawdopodobieństwem). Rozwiązania zakodowane są w macierzach stanów JW, które mają wymiary $(N \text{ jednostek}) \times (T \text{ godzin})$. Krzyżowanie polega na przecięciu dwóch macierzy osobników rodzicielskich w punkcie $t \in \{1, 2, \dots, T\}$ i krzyżowym ich sklejeniu. Po krzyżowaniu nie ma konieczności ponownego rozdziału obciążeń dla osobników potomnych,

ponieważ jest on taki sam (dla poszczególnych godzin) jak dla osobników rodzicielskich. W przypadku naruszenia przez rozwiązania ograniczeń, są one korygowane. Stosuje się mutację pojedynczych bitów, strategię elitarną i selekcję ruletkową. Aby poprawić zdolność przeszukiwania lokalnego, działanie AG wspomaga system ekspercki, modyfikujący ostateczne rozwiązania. Algorytm osiągał lepsze rezultaty od relaksacji Lagrange'a.

W [Man99a] i [Man99b] do wspomaganie działania AG stosuje się metodę przeszukiwania tabu (*tabu search*). W każdej generacji algorytmu genetycznego uruchamia się algorytm tabu, który przeszukuje przestrzeń wokół losowo wybranych osobników. Metodę tabu użyto do DSJW w [Bai97]. Algorytm tabu ukierunkowywany jest na obiecujące i dopuszczalne regiony przestrzeni rozwiązań, poprzez metodę dekompozycji Bandersa (*Banders decomposition*). Punkt startowy do algorytmu tabu dobierany jest za pomocą relaksacji Lagrange'a. W [Jus99] przedstawiono ciekawy sposób kodowania harmonogramów pracy JW (za pomocą liczb całkowitych), zależny od minimalnych czasów pracy i postojów jednostek, oraz dostosowane do tego kodowania operatory genetyczne.

Algorytm symulowanego wyżarzania (SW), przeznaczony głównie do zadań optymalizacji kombinatorycznej, z powodzeniem stosowano do zadania DSJW. Podobnie jak algorytmy ewolucyjne, algorytm ten jest mało wrażliwy na punkt startowy, umożliwia dowolne kształtowanie funkcji kryterialnej i należy do metod optymalizacji globalnej. Algorytm SW nie ma jednak struktury równoległej, rozwiązania przetwarzane są sekwencyjnie, co wymaga długiego czasu obliczeń. W procesie wyżarzania rozwiązania modyfikowane są za pomocą operatora przesunięcia, wprowadzającego drobne zakłócenia punktu bazowego. Punkt startowy algorytmu może być dobrany losowo lub za pomocą innej metody (np. listy priorytetowej). Ograniczenia mogą być włączone do funkcji kryterialnej w postaci funkcji karnych.

Specjalizowany operator przesunięcia w SW, zaproponowany w [Man98], pozwala generować rozwiązania dopuszczalne i ok. dwukrotnie skrócić czas obliczeń. Modyfikacje rozwiązań polegają na przesuwaniu czasów wyłączeń lub załączeń JW. Autorzy stosują statyczną i adaptacyjną strategię wyżarzania. Wyniki są lepsze od otrzymanych innymi metodami: metodą relaksacji Lagrange'a i metodą programowania całkowitoliczbowego. W [Won98b] zastosowano podobny operator przesunięcia, przy czym dla punktów generowanych w procesie wyżarzania, wprowadza się szereg reguł logicznych kontrolujących ograniczenia i korygujących rozwiązania DSJW. Dla otrzymanych w ten sposób dopuszczalnych harmonogramów pracy JW uruchamia się inny proces wyżarzania, w którym określa się ekonomiczne obciążenia JW.

Algorytm hybrydowy sieci neuronowej i symulowanego wyżarzania zaproponowano w [Nay00]. Sieć (trójwarstwowy perceptron) jest trenowana wektorami zapotrzebowania dobowego i skojarzonymi z nimi wektorami harmonogramów pracy JW (dającymi najniższe koszty i spełniającymi ograniczenia). W fazie odtworzeniowej, dla zadanego na wejściu przebiegu zapotrzebowania, sieć zwraca bliski optymalnemu harmonogram. Zadaniem SW jest określenie dla tego harmonogramu obciążeń JW. W SW losowo generuje się dopuszczalne poziomy obciążenia JW, które dalej przetwarza się w procesie wyżarzania. W

[Won00] sieć neuronowa realizuje podobne odwzorowanie: prognozy zapotrzebowania na harmonogram pracy JW. Połączenia w sieci neuronowej oraz wagi dobierane są adaptacyjnie przez algorytm ewolucyjny.

W pracy [Lia94b] sieci neuronowych używa się do planowania pracy elektrowni wodnych, przy czym minimalizuje się koszty generacji jednostek ciepłych, podobnie jak w [Lia94a]. W pierwszej fazie algorytmu grupuje się dni o podobnych przebiegach zapotrzebowania i podobnych krzywych określających wielkości wpływów wody do zbiorników elektrowni wodnych. Grupowania dokonuje sieć neuronowa z konkurencyjną regułą uczenia. Dla każdej grupy projektuje się sieć typu wielowarstwowego perceptronu, której zadaniem jest wstępny rozdział obciążeń na elektrownie wodne. Rozwiązania otrzymane z sieci neuronowych koryguje się w sposób heurystyczny tak, aby spełniały zadane ograniczenia. Rozwiązania po korekcie są bliskie optymalnym, otrzymanym za pomocą programowania dynamicznego. Czas działania proponowanego algorytmu jest znacznie krótszy od czasu działania programowania dynamicznego.


Podejście stochastyczne do problemu DSJW i ERO zaprezentowano w [Kas97]. W podejściu tym przebieg zapotrzebowania i dyspozycyjność JW nie są deterministyczne, modeluje się je za pomocą odpowiednich rozkładów prawdopodobieństw. Wobec tych założeń problem DSJW i ERO jest stochastyczny; minimalizacji podlega wartość oczekiwana funkcji kosztu. W celu rozwiązania tego problemu autorzy definiują stochastyczną odmianę sieci Hopfielda. Sieć została przetestowana na zadaniu o niewielkim rozmiarze: 3 JW i okres optymalizacji $T = 4$ h.

Sieć neuronową z rozmytą warstwą wejściową, pozwalającą modelować nieprecyzyjność prognozy przebiegu zapotrzebowania, zaprezentowano w [Pad97] i [Pad00]. Otrzymane na wyjściu sieci harmonogramy pracy JW (wektory binarne) analizowane są przez adaptacyjny system ekspercki. Przebieg zapotrzebowania definiowany jest za pomocą zmiennych lingwistycznych. Wartości zapotrzebowania transponuje się na zmienne rozmyte za pomocą pięciu zbiorów rozmytych i określonych dla nich trójkątnych funkcji przynależności. Reguły zawarte w systemie eksperckim pozwalają korygować rozwiązania, jeśli naruszają one ograniczenia. Przeprowadzone w [Pad00] badania porównawcze algorytmów świadczą o skuteczności proponowanej metody hybrydowej, która dawała rozwiązania nieznacznie gorsze od optymalnych (wyznaczonych za pomocą programowania dynamicznego) i porównywalne do otrzymanych za pomocą AG (w tym przypadku czas obliczeń był jednak znacznie krótszy – od 3 do 20 razy).

4. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ NA POZIOMIE ELEKTROWNI

4.1. SFORMUŁOWANIE ZADANIA. FUNKCJA KOSZTU. OGRANICZENIA

Zadanie polega na wyznaczeniu optymalnych obciążeń netto $P_{ni}(t)$ pracujących w elektrowni jednostek wytwórczych w okresie $T = 24$ h. Okres T zdyskretyzowano na 24 godzinne przedziały $t = 1, 2, \dots, 24$. Przyjęto dwanaście jednostek wytwórczych ($i = 1, 2, \dots, 12$), co odpowiada rozmiarowi największej polskiej elektrowni. Jednostki opisane są charakterystykami: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych strumieni kosztów zmiennych $\varepsilon_{ki}(P_{ni})$ oraz kosztów rozruchów $K_{ri}(t_{pi})$. Charakterystyki te skonstruowano wg metodyki opisanej w podrozdziale 4.3. Przyjęto dyskretny przebieg zapotrzebowania dobowego mocy $P_z(t)$ (rys. 4.1), zadanego dla elektrowni przez Krajową Dyspozycję Mocy, który odpowiada kształtem rzeczywistemu przebiegowi zapotrzebowania w KSE (z drugiej grudniowej środy 1994 r.). Przebieg ten powstał poprzez przeskalowanie liniowe przebiegu zapotrzebowania w systemie. Przyjęto, że obciążenie szczytowe odpowiada sumie mocy osiągalnych dziesięciu JW (3500 MW), a obciążenie minimalne w dolinie nocnej – sumie minimów technicznych dziesięciu JW (1800 MW). Najmniejsze zapotrzebowanie dobowe P_{zmin} stanowi ok. 51% zapotrzebowania szczytowego P_{zmax} . Szeroki zakres zmian mocy P_z zwiększa przestrzeń rozwiązań i tym samym trudność zadania. W praktyce zakres ten zależy od roli elektrowni w SEE (elektrownia podstawowa, podszczytowa, szczytowa).



Rys. 4.1. Przyjęty przebieg zapotrzebowania mocy. Źródło: opracowanie własne.

Poziom rezerwy wirującej, niezbędny dla pokrycia wahań obciążenia i nieplanowych ubytków mocy wytwórczej, dla całego KSE określa się ze wzoru [Kot00]:

$$P_{rw}(t) = \varphi P_{zmax} \quad t = 1, 2, \dots, T \quad (4.1)$$

gdzie: $P_{rw}(t)$ – wymagany w chwili t poziom rezerwy wirującej, MW; φ – współczynnik równy 0,05; P_{zmax} – szczytowe zapotrzebowanie mocy w okresie T , MW.

Dodatkowo wielkość tej rezerwy w KSE nie powinna być mniejsza od podwojonej mocy znamionowej największej jednostki w ruchu. Zakłada się, że wielkość rezerwy wirującej jest zadana elektrowni przez KDM. Ogdórny rozdział wymaganej rezerwy wirującej na elektrownie ma zapewnić możliwie równomierny jej rozkład w SEE i pozwala uniknąć nadmiernej jej koncentracji w jednej lub tylko kilku elektrowniach. Przyjęto, że w modelowanej elektrowni poziom rezerwy wirującej wyznacza się ze wzoru (4.1), dla $\varphi = 0,05$ i $P_{zmax} = 3500$ MW, stąd $P_{rw}(t) = 175$ MW dla $t = 1, 2, \dots, T$.

Za wskaźnik jakości optymalizacji przyjmuje się sumę kosztów zmiennych na produkcję energii elektrycznej w okresie optymalizacji T , powiększoną o koszty rozruchów jednostek:

$$F_P = \sum_{t=1}^T \sum_{i=1}^N \left\{ \alpha_i(t) K_{zi} [P_{ni}(t)] \Delta t + \alpha_i(t) [1 - \alpha_i(t-1)] K_{ri}(t_{pi}) \right\} \quad (4.2)$$

w którym: t – numer godziny ($t = 1, 2, \dots, T$); Δt – krok dyskretyzacji czasu, przyjęto $\Delta t = 1$; T – horyzont optymalizacji, przyjęto $T = 24$ h; i – numer jednostki wytwórczej ($i = 1, 2, \dots, N$); N – liczba dyspozycyjnych jednostek wytwórczych w elektrowni, przyjęto $N = 12$; $K_{zi} [P_{ni}(t)]$ – strumień kosztu zmiennego wytwarzania i -tej jednostki przy obciążeniu P_{ni} , zł/h; $P_{ni}(t)$ – obciążenie netto i -tej jednostki w chwili t , MW; $K_{ri}(t_{pi})$ – koszt odstawienia, postoju i rozruchu i -tej jednostki po czasie postoju t_{pi} , zł; t_{pi} – czas postoju i -tej jednostki w rezerwie, h; $\alpha_i(t)$ – funkcja binarna określona wzorem:

$$\alpha_i(t) = \begin{cases} 1, & \text{gdy jednostka } i \text{ - ta pracuje w chwili } t \\ 0, & \text{gdy jednostka } i \text{ - ta jest odstawiona w chwili } t \end{cases} \quad (4.3)$$

Aby uwzględnić koszty związane z decyzją o odstawieniu jednostki w chwili t , w przypadku gdy pozostaje ona w postoju do końca okresu T , zakłada się że:

- koszty związane z rozruchem jednostki rozkładają się równomiernie na poszczególne godziny jej postoju,
- rozruch jednostki nastąpi w chwili τ , odliczanej od momentu zakończenia okresu optymalizacji T ($\tau \in \{1, 2, 3, \dots\}$).

Przy tych założeniach, koszty rozruchu jednostki ponoszone w okresie T oblicza się ze wzoru:

$$K_r(T-t) = \frac{K_r(T-t+\tau)}{T-t+\tau} (T-t) \quad (4.4)$$

gdzie: τ – przewidywany czas postoju jednostki po zakończeniu okresu optymalizacji T . Dla przyjętego przebiegu zapotrzebowania, przy założeniu, że przebieg zapotrzebowania w kolejnej dobie będzie podobny do przebiegu w okresie T , przyjęto $\tau = 7$ h, gdyż o godzinie 8 obserwuje się gwałtowny wzrost zapotrzebowania.

Na rozwiązania narzuca się ograniczenia określone przez:

- bilans mocy – suma mocy wytwarzanej przez jednostki równa jest zadanej mocy zapotrzebowanej w każdej chwili okresu optymalizacji:

$$\forall t: \sum_{i=1}^N [\alpha_i(t)P_{ni}(t)] = P_z(t) \quad (4.5)$$

- zakresy generacji poszczególnych jednostek – obciążenie jednostki leży w zakresie od minimum technicznego do mocy osiągalnej lub jest zerowe:

$$\forall i, t: \alpha_i(t)P_{n\min i} \leq P_{ni} \leq \alpha_i(t)P_{n\max i} \quad (4.6)$$

- zakres generacji grupy jednostek – współpracujące jednostki muszą zapewnić pokrycie zapotrzebowania, z uwzględnieniem rezerwy wirującej, w każdej chwili okresu optymalizacji, tzn. suma minimum technicznych pracujących jednostek nie może być większa od zadanego zapotrzebowania i jednocześnie suma ich mocy osiągalnych nie może być mniejsza od zapotrzebowania i wymaganej rezerwy wirującej:

$$\forall t: \sum_{i=1}^N [\alpha_i(t)P_{n\min i}] \leq P_z(t) \quad (4.7)$$

$$\forall t: \sum_{i=1}^N [\alpha_i(t)P_{n\max i}] \geq P_z(t) + P_{rw}(t) \quad (4.8)$$

- minimalne czasy postojów jednostek w rezerwie – czas postoju JW w rezerwie nie może być krótszy od jej dopuszczalnego minimalnego czasu postoju:

$$\forall i: t_{pi} \geq t_{p\min i} \quad (4.9)$$

- minimalne czasy pracy jednostek po rozruchu – czas pracy JW po rozruchu nie może być krótszy od jej dopuszczalnego minimalnego czasu pracy:

$$\forall i: t_{ri} \geq t_{r\min i} \quad (4.10)$$

gdzie: $t = 1, 2, \dots, T$; $i = 1, 2, \dots, N$; $P_{n\min i}$, $P_{n\max i}$ – odpowiednio minimum techniczne i moc osiągalna jednostki i -tej, MW; $t_{p\min i}$ – minimalny czas postoju jednostki i -tej w rezerwie, h; t_{ri} – czas pracy jednostki i -tej po rozruchu, h; $t_{r\min i}$ – minimalny czas pracy jednostki i -tej po rozruchu, h.

Rozwiązanie zadania zależne jest od stanu początkowego jednostek, które bezpośrednio przed okresem optymalizacji T mogą znajdować się w ruchu lub w rezerwie. Stan początkowy reprezentuje zmienna t_{psi} , oznaczająca liczbę godzin postoju (jeśli $t_{psi} > 0$) lub pracy ($t_{psi} < 0$) jednostki i -tej przed pierwszą godziną okresu optymalizacji. Przykładowo $t_{psi} = 24$ oznacza, że jednostka i -ta w godzinie poprzedzającej okres T znajduje się od 24 h w rezerwie; $t_{psi} = -24$ oznacza, że jednostka i -ta w godzinie poprzedzającej okres T znajduje się od 24 h w ruchu.

Przyjęte parametry charakteryzujące jednostki wytwórcze zestawiono w tablicy 4.1.

Tablica 4.1. Wartości parametrów opisujących jednostki wytwórcze przyjęte w zadaniu ERO na poziomie elektrowni. Źródło: opracowanie własne.

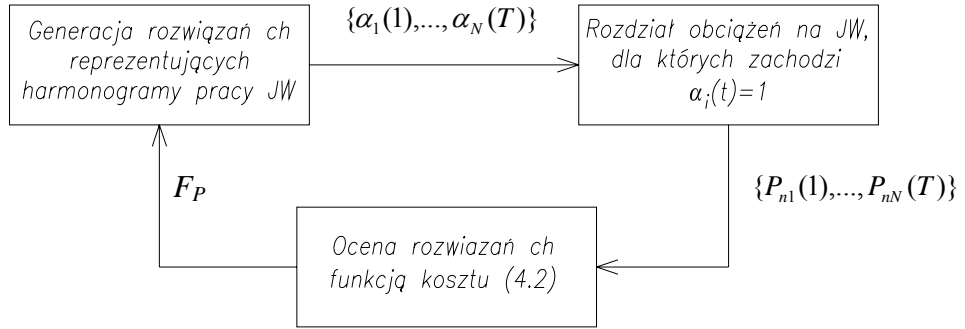
Parametr	Jednostka nr											
	1	2	3	4	5	6	7	8	9	10	11	12
P_{nmini} , MW	180	180	180	180	180	180	180	180	180	180	180	180
P_{nmaxi} , MW	350	350	350	350	350	350	350	350	350	350	350	350
t_{pmini} , h	5	5	5	5	5	5	5	5	5	5	5	5
t_{rmini} , h	5	5	5	5	5	5	5	5	5	5	5	5
t_{psi} , h	24	4	4	-24	-24	-24	-24	-24	-24	-24	-24	-24

4.2. METODYKI ROZWIĄZANIA ZADANIA EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ

W pracy do zadania ekonomicznego rozdziału obciążeń na poziomie elektrowni stosuje się dwa podejścia:

1. kombinowane – ERO-k:
 - 1.1. z wykorzystaniem algorytmów ewolucyjnych,
 - 1.2. z wykorzystaniem algorytmów symulowanego wyżarzania,
 - 1.3. z wykorzystaniem algorytmu hybrydowego SW i AE,
2. zintegrowane – ERO-z:
 - 2.1. z wykorzystaniem kompleksowego algorytmu ewolucyjnego,
 - 2.2. z wykorzystaniem sekwencyjnego algorytmu ewolucyjnego.

W pierwszym podejściu dziedziną poszukiwań AE i SW jest przestrzeń stanów „jednostka załączona” – „jednostka odstawiona”, dla wszystkich chwil t okresu optymalizacji T . Jest to zadanie kombinatoryczne, które sprowadza się do wyznaczenia funkcji binarnych $\alpha_i(t)$, czyli ustalenia harmonogramów pracy jednostek wytwórczych. Zadanie to można utożsamiać z zadaniem DSJW. Rozdział obciążeń na jednostki, dla których zachodzi $\alpha_i(t) = 1$ sam w sobie stanowi tu odrębny problem programowania nieliniowego, który rozwiązuje się dla każdej chwili t (ERO „w punkcie”) klasyczną metodą mnożników Lagrange'a, a więc deterministycznie. Procedury optymalizacyjne ERO-k działają cyklicznie wg schematu przedstawiono na rys. 4.2.



Rys. 4.2. Schemat poglądowy procedur ERO-k. Źródło: opracowanie własne.

Nowe rozwiązania generuje się w procesie ewolucyjnym lub w procesie wyzarcia, przetwarzając rozwiązania z poprzedniego cyklu i korzystając z informacji o ich kosztach F_P . Rozdziału obciążeń na JW według równych przyrostów względnych kosztów zmiennych, dokonuje się metodą kolejnych przybliżeń przedstawioną poniżej [Gła99], [Woo96]:

1. Dla danych: zapotrzebowania P_z , charakterystyk przyrostów względnych JW $\varepsilon_{ki}(P_{ni})$, składu jednostek reprezentowanego przez zmienne α_i , minimalnego przyrostu względnego składu ε_{\min} (przy którym wszystkie jednostki pracują przy swoich minimach technicznych) oraz przyrostu maksymalnego ε_{\max} (przy którym wszystkie jednostki pracują z mocą osiągalną), wyznaczanych ze wzorów:

$$\varepsilon_{\min} = \min_{\alpha_i=1} \{ \varepsilon_{ki} (P_{n \min i}) \} \quad (4.11)$$

$$\varepsilon_{\max} = \max_{\alpha_i=1} \{ \varepsilon_{ki} (P_{n \max i}) \} \quad (4.12)$$

powtarzają do momentu spełnienia warunku (4.13):

- 1.1. Oblicz: $\varepsilon' = \frac{\varepsilon_{\min} + \varepsilon_{\max}}{2}$.

- 1.2. Wyznacz obciążenia jednostek przy przyroście ε' : $P_{ni}(\varepsilon')$.

- 1.3. Sprawdź warunek:

$$\left| \sum_{i=1}^N [\alpha_i P_{ni}(\varepsilon')] - P_z \right| \leq \delta_p \quad (4.13)$$

gdzie: δ_p – zadany maksymalny błąd.

- 1.4. Jeśli warunek (4.13) nie jest spełniony sprawdź warunek:

$$\sum_{i=1}^N [\alpha_i P_{ni}(\varepsilon')] > P_z \quad (4.14)$$

Jeśli warunek (4.14) jest spełniony przyjmij $\varepsilon_{\max} = \varepsilon'$, w przeciwnym wypadku:

$$\varepsilon_{\min} = \varepsilon'.$$

Algorytm ten jest zbieżny po kilkunastu iteracjach do optymalnego dla zadanego składu rozwiązania [Woo96], jeśli charakterystyki kosztów zmiennych JW są ciągłe i wypukłe. Algorytm przedstawiony powyżej zaprogramowano w funkcjach KOSZT1.m i KOSZT2.m (dodatek 8). Maksymalny błąd δ_p dobrano w ten sposób, aby koszty rozwiązań wyznaczone były z tolerancją mniejszą od 1 zł (patrz podrozdział 4.6).

W podejściu zintegrowanym (ERO-z) algorytmy ewolucyjne rozwiązują jednocześnie zadanie DSJW i zadanie optymalnego obciążenia jednostek. W tym przypadku nie ma ograniczeń co do charakterystyk kosztów zmiennych jednostek, nie muszą one być ciągłe, różniczkowalne i wypukłe, czego wymaga metoda ERO według równych przyrostów względnych. Proponuje się tutaj kompleksowy algorytm ewolucyjny, optymalizujący harmonogramy i obciążenia JW w całym okresie T oraz sekwencyjny algorytm ewolucyjny, optymalizujący obciążenia dla kolejnych godzin okresu T .

W podrozdziale 4.4 przedstawiono algorytmy optymalizacyjne realizujące podejście ERO-k, natomiast w podrozdziale 4.5 – podejście ERO-z. Zaproponowano szereg sposobów reprezentacji zmiennych, operatorów genetycznych w AE i operatorów przesunięcia w algorytmie SW, różne strategie wyżarzania w SW oraz różne strategie postępowania z rozwiązaniami niespełniającymi ograniczeń. Przeprowadzono masowe obliczenia komputerowe stosując różne warianty algorytmów optymalizacyjnych w celu porównania ich efektywności i wytypowania najlepszych algorytmów realizujących podjęte zadanie.

Krótkie wprowadzenie do algorytmów ewolucyjnych i symulowanego wyżarzania, problemy związane z projektowaniem modeli optymalizacyjnych na bazie tych algorytmów oraz terminologię AE zawarto w dodatku 2.

Funkcja kosztu (4.2), minimalizowana we wszystkich prezentowanych algorytmach optymalizacyjnych, wymaga definicji charakterystyk kosztów zmiennych oraz charakterystyk kosztów rozruchu JW. Sposób konstrukcji tych charakterystyk przedstawiono w podrozdziale 4.3.

4.3. CHARAKTERYSTYKI KOSZTÓW ZMIENNYCH I KOSZTÓW ROZRUCHÓW BLOKÓW ENERGETYCZNYCH

Koszty wytwarzania energii elektrycznej w elektrowniach dzieli się na koszty stałe – zależne od mocy zainstalowanej oraz koszty zmienne – zależne od wytworzonej energii elektrycznej. Koszty zmienne mogą być zależne lub niezależne od obciążenia elektrowni. Koszty zależne od obciążenia obejmują:

- koszty paliwa (węgla, oleju opałowego, gazu),
- koszty transportu paliwa do elektrowni,
- koszty materiałów pomocniczych (wody, chemikaliów, smarów itp.),
- koszty gospodarczego użytkowania środowiska naturalnego.

Do kosztów niezależnych od obciążenia zalicza się koszty odstawień i rozruchów. Klasyfikacja kosztów paliwa rozpałowego i podstawowego oraz materiałów pomocniczych zużywanych podczas rozruchu do kosztów zmiennych jest umowna [Lau99], ponieważ podczas odstawienia i rozruchu nie wytwarza się energii elektrycznej. Do kosztów niezależnych od obciążenia zalicza się także koszty remontów i przeglądów spowodowanych częstymi rozruchami. Składnik kosztów zmiennych zależnych od obciążenia nazwano w pracy kosztami zmiennymi, natomiast składnik kosztów zmiennych niezależnych od obciążenia nazwano kosztami rozruchów.

W kosztach zmiennych można jeszcze wyróżnić tzw. koszty umownie stałe: koszty osobowe personelu ruchowego oraz koszty utrzymania i remontów zależne od obciążenia. Z uwagi na okresowy charakter kosztów remontów, występujących z różnym nasileniem, uwzględnienie ich w charakterystykach kosztów zmiennych JW jest kłopotliwe. Nie uwzględnia się też kosztów osobowych personelu ruchowego, ponieważ koszty te trudno rozdzielić na poszczególne bloki energetyczne.

Charakterystyki kosztów zmiennych i kosztów rozruchów wyznaczono na bazie charakterystyk energetycznych $Q_d = f(P_n)$ oraz charakterystyk strat rozruchowych $Q_r = f(t_p)$. W dodatku 1 opisano sposób określania tych charakterystyk i metody uwzględnienia wpływu czynników eksploatacyjnych na charakterystyki energetyczne: metodę techniczno – ekonomicznej kontroli pracy elektrowni (TKE), metodę aproksymacji statystycznej oraz propozycje modeli aproksymacyjnych opartych na sieciach neuronowych. W dodatku tym poruszono tematykę elastyczności ruchowej JW. Przedstawiono sposoby określania rozruchowych strat energii, czynniki wpływające na te straty oraz wzory aproksymujące straty rozruchowe.

4.3.1. KOSZTY PALIWA I MATERIAŁÓW POMOCNICZYCH

Koszty paliwa w elektrowniach cieplnych ujmują koszty paliwa podstawowego (węgiel kamienny, węgiel brunatny, gaz ziemny, olej opałowy) oraz koszty paliwa rozpałowego (olej opałowy, mazut, propan – butan, olej lekki, olej dieslowski, gaz ziemny).

W kosztach tych zawarte są koszty płacone dostawcom i przewoźnikom. Koszty paliwa rozpałowego uwzględniono w charakterystykach kosztów rozruchów.

Charakterystyka kosztów paliwa podstawowego powstaje z przeliczenia charakterystyki zużycia energii według wzoru:

$$K_p(P_n) = B(P_n)(c_{jzp} + c_{jtp}) = \frac{Q_d(P_n)}{W}(c_{jzp} + c_{jtp}) \cdot 10^3 \quad (4.15)$$

gdzie: K_p – strumień kosztu paliwa podstawowego, zł/h; B – godzinowe zużycie paliwa podstawowego, Mg/h; Q_d – strumień energii chemicznej doprowadzonej do kotła w paliwie, GJ/h; P_n – obciążeniu netto bloku, MW; W – wartość opałowa paliwa podstawowego, kJ/kg; c_{jzp} , c_{jtp} – odpowiednio cena jednostkowa zakupu paliwa podstawowego i opłata jednostkowa za jego transport do elektrowni, zł/Mg.

Koszty materiałów dodatkowych (pomocniczych) obejmują koszty zakupu, transportu i przygotowania [Lau99]: wody (kotłowej, ruchowej, chłodzącej, pitnej) i chemikaliów do jej uzdatniania, olejów, smarów, farb, chemikaliów do neutralizacji ścieków, materiałów izolacyjnych i dźwiękochłonnych, kul do młynów węglowych, bijaków do kruszarek węgla i żużła, szczotek do generatorów i silników, czyściwa i innych.

Koszty godzinowe związane ze zużyciem materiałów dodatkowych proponuje się wyznaczać ze wzoru:

$$K_{md}(P_n) = B(P_n) \sum_x (w_{zx} c_{jx}) = \frac{Q_d(P_n)}{W} \sum_x (w_{zx} c_{jx}) \cdot 10^3 \quad (4.16)$$

w którym: K_{md} – godzinowy koszt związany ze zużyciem materiałów dodatkowych, zł/h; w_{zx} – wskaźnik zużycia x -tego materiału dodatkowego w m³/Mg paliwa lub kg/Mg paliwa; c_{jx} – koszt jednostkowy zakupu, transportu i przygotowania materiału typu x , zł/m³ lub zł/kg.

Wskaźniki zużycia można oszacować na podstawie rzeczywistego zużycia materiałów dodatkowych w okresie T_a (np. miesiąc, rok):

$$w_{zx} = z_{\Sigma x} \frac{\bar{W}}{Q_{d\Sigma}} 10^{-3} \quad (4.17)$$

gdzie: $z_{\Sigma x}$ – całkowite zużycie materiału x w okresie T_a , kg lub m³; $Q_{d\Sigma}$ – całkowita energia chemiczna paliwa zużytego w okresie T_a , GJ; \bar{W} – średnia wartość opałowa paliwa podstawowego w okresie T_a , kJ/kg.

W przypadku bloków energetycznych wyposażonych w instalacje odsiarczania spalin (IOS), w modelu należy uwzględnić koszty ich eksploatacji, które zależne są od technologii odsiarczania. Z uwagi na zaostrzenie krajowych norm emisji SO₂ w ostatnich latach (ok. 6-ciokrotne obniżenie poziomu dopuszczalnej emisji SO₂ dla dużych źródeł), od IOS wymaga się wysokich skuteczności i niezawodności. Najbardziej rozpowszechnione są mokre metody

wapienne i wapniowe [Kuc97], [Dag97], które charakteryzują się dużą skutecznością odsiarczania (80 – 95%). Funkcją sorbentu w tych metodach spełnia wodna zawiesina kamienia wapiennego lub wapna. Produktem ubocznym jest siarczan wapnia, który po procesie utleniania przyjmuje postać gipsu. W ostatnich latach opracowano w kraju oryginalną technologię suchą z nawilżaniem, wdrożoną w Elektrowni Rybnik [Por00], która wykazuje niskie koszty inwestycyjne i eksploatacyjne oraz wysoką skuteczność (do 85%). W modelowanej elektrowni na blokach 8, 10, 11 i 12 zainstalowano IOS w technologii mokrej wapiennej o gwarantowanej skuteczności odsiarczania powyżej 90% [Paw98].

Koszty eksploatacyjne IOS obejmują koszt sorbentu, koszt wody technologicznej, koszt energii elektrycznej, koszt odprowadzania ścieków i składowania odpadów. Godzinowe zużycie sorbentu oraz wody można wyznaczyć ze wzorów:

$$m_s(P_n) = w_{zs} B(P_n) s = w_{zs} s \frac{Q_d(P_n)}{W} 10^3 \quad (4.18)$$

$$z_{wIOS}(P_n) = w_{zwIOS} B(P_n) = w_{zwIOS} \frac{Q_d(P_n)}{W} 10^3 \quad (4.19)$$

gdzie: m_s , w_{zs} – zużycie i wskaźnik zużycia sorbentu w IOS dla paliwa podstawowego, odpowiednio w Mg/h i Mg/(Mg·%); z_{wIOS} , w_{zwIOS} – zużycie i wskaźnik zużycia wody w IOS, odpowiednio w m³/h i m³/Mg paliwa; s – procentowa zawartość siarki w paliwie, %.

Wskaźniki zużycia wody i kamienia wapiennego (wapna) oblicza się na podstawie danych dostarczonych przez producenta instalacji.

Godzinowe koszty materiałów eksploatacyjnych w IOS można wyrazić wzorem:

$$K_{meIOS}(P_n) = m_s(P_n) c_{js} + z_{wIOS}(P_n) c_{jw} \quad (4.20)$$

w którym: K_{meIOS} – godzinowy koszt materiałów eksploatacyjnych zużytych w IOS, zł/h; c_{js} – cena jednostkowa zakupu, transportu i przygotowania sorbentu, zł/Mg; c_{jw} – cena jednostkowa wody, zł/m³.

W blokach wyposażonych w instalacje odazotowywania gazów odlotowych koszty zmienne zwiększają się o koszty eksploatacji tych instalacji. Instalacje odazotowywania buduje się najczęściej w technologii selektywnej redukcji katalitycznej lub selektywnej redukcji niekatalitycznej [Dag97]. Skuteczność droższej inwestycyjnie i eksploatacyjnie metody katalitycznej wynosi od 70 do 90%, natomiast metody niekatalitycznej od 50 do 70%. Koszty eksploatacyjne składają się z kosztów amoniaku, kosztów katalizatora (w metodzie katalitycznej) oraz kosztów zużytej energii elektrycznej. Katalizatorem jest porowaty element z substancją aktywną – pięciotlenkiem wanadu lub inną. W wyniku reakcji amoniaku z tlenkami azotu powstaje azot i woda. Godzinowe zużycie amoniaku można określić ze wzoru:

$$z_{NH_3}(P_n) = w_{zNH_3} B(P_n) = w_{zNH_3} \frac{Q_d(P_n)}{W} 10^3 \quad (4.21)$$

gdzie: z_{NH_3}, w_{zNH_3} – zużycie i wskaźnik zużycia amoniaku w instalacji odazotowywania spalin, odpowiednio w m^3/h i m^3/Mg paliwa.

Katalizator ulega zużyciu po 2 ÷ 5 latach, zależnie od stopnia zapylenia spalin. Dla 1 MW mocy elektrowni potrzeba 1 m^3 katalizatora [Kuc97]. Godzinowe zużycie katalizatora można w przybliżony sposób wyznaczyć ze wzoru:

$$z_{kat}(P_n) = w_{zkat} B(P_n) p = w_{zkat} p \frac{Q_d(P_n)}{W} 10^3 \quad (4.22)$$

gdzie: z_{kat}, w_{zkat} – zużycie i wskaźnik zużycia katalizatora w instalacji odazotowywania spalin, odpowiednio w m^3/h i $m^3/(Mg \cdot \%)$; p – zawartość popiołu w paliwie, %.

Wskaźniki w_{zNH_3} i w_{zkat} oblicza się na podstawie danych otrzymanych od producenta instalacji.

Godzinowe koszty materiałów eksploatacyjnych instalacji odazotowywania spalin wyznacza się ze wzoru:

$$K_{meNO_x}(P_n) = z_{NH_3}(P_n) c_{jNH_3} + z_{kat}(P_n) c_{jkat} \quad (4.23)$$

w którym: K_{meNO_x} – godzinowy koszt materiałów eksploatacyjnych zużytych w instalacji odazotowywania spalin, $zł/h$; c_{jNH_3} – cena jednostkowa zakupu, transportu i przygotowania amoniaku, $zł/m^3$; c_{jkat} – cena jednostkowa katalizatora, $zł/m^3$.

Koszty eksploatacyjne kotłów fluidalnych obejmują oprócz kosztów paliwa także koszty kamienia wapiennego lub dolomitu wykorzystywanego do wiązania siarki zawartej w węglu. Palenisko fluidalne umożliwia zmniejszenie emisji tlenków siarki do atmosfery nawet o 95% [Kuc97]. Zużycie sorbentu można wyznaczyć na podstawie wzoru (4.18).

4.3.2. KOSZTY UŻYTKOWANIA ŚRODOWISKA NATURALNEGO

W ostatnich latach obserwuje się tendencję znacznego wzrostu opłat za korzystanie ze środowiska naturalnego, a co za tym idzie wzrost składnika kosztów związanych z użytkowaniem środowiska w ogólnych kosztach zmiennych wytwarzania energii elektrycznej. Niektóre opłaty na przestrzeni ostatniego dziesięciolecia wzrosły kilkakrotnie, a w przypadku tlenku węgla nawet osiemdziesięciokrotnie [Olk00]. Największy udział w zanieczyszczeniu powietrza ma sektor elektroenergetyczny. Wysokie opłaty zmuszają producentów energii do inwestycji proekologicznych oraz optymalizacji pracy urządzeń wytwórczych pod kątem minimalizacji emisji zanieczyszczeń. Możliwość zmniejszenia zanieczyszczeń stwarza odpowiednia realizacja ERO.

Opłaty związane z gospodarczym wykorzystywaniem środowiska naturalnego obejmują [DzU99a], [DzU99b], [Lau99]:

- opłaty za wprowadzanie do powietrza atmosferycznego pyłu ze spalania paliw, dwutlenku siarki, tlenków azotu, dwutlenku i tlenku węgla, zł/kg,
- opłaty za składowanie popiołu lotnego, żużla i odpadów z wapniowych metod odsiarczania spalin, zł/Mg,
- opłaty za wodę zużytą bezpowrotnie do celów związanych z wytwarzaniem energii elektrycznej (woda uzupełniająca, woda dodatkowa) oraz wodę pobieraną z miejskiej sieci wodociągowej, zł/m³,
- opłaty za ścieki z elektrowni, zł/Mg.

Emisję pyłu, SO₂ oraz NO_x można określić teoretycznie w przybliżony sposób, na podstawie analizy fizykochemicznej próbki węgla oraz danych eksploatacyjnych pracy paleniska. W świetle postanowień rozporządzenia [DzU98e] pomiary stężeń substancji zanieczyszczających w gazach odlotowych prowadzi się w sposób ciągły, jeżeli moc źródła wynosi co najmniej 300 MW_t lub gdy wspólnym emitorem odprowadzane są gazy odlotowe ze źródeł o łącznej mocy cieplnej co najmniej 300 MW_t.

W zależności od warunków spalania, mineralne składniki paliw stałych mogą tworzyć żużel, popiół bądź pył. Przy niecałkowitym spalaniu pył może zawierać także ziarna węgla. Ilość pyłów powstających w procesie spalania paliw stałych zależy od rodzaju paliwa (stopnia rozdrobnienia, zawartości popiołu, składu mineralogicznego popiołu i in.) oraz warunków spalania (rodzaju rusztu, natężenia cieplnego komory paleniskowej, temperatury spalania, współczynnika nadmiaru powietrza i in.) [Jud74]. Emisję pyłu w praktyce wyznacza się pomiarowo mierząc stężenie pyłu za pomocą pyłomierzy oraz natężenie przepływu spalin [Kuc97]. Całkowitą emisję pyłu wyznacza się ze wzoru:

$$E_p(P_n) = w_{up} B(P_n) \frac{p}{\left(1 - \frac{c_p}{100}\right)} \left(1 - \frac{\eta_{odp}}{100}\right) = w_{up} Q_d(P_n) \frac{p(100 - \eta_{odp})}{W(100 - c_p)} 10^3 \quad (4.24)$$

gdzie: E_p – emisja pyłu w kg/h; w_{up} – wskaźnik unosu pyłu w kg/(Mg·%); c_p – zawartość części palnych w pyle, %; η_{odp} – skuteczność urządzeń odpylających, %.

Ilość emitowanych tlenków siarki zależy głównie od zawartości tego pierwiastka w paliwie, a w niewielkim stopniu od rodzaju paleniska [Jud74]. Emisję SO₂ w zależności od energii chemicznej paliwa spalanego w kotle, wskaźnika unosu i zawartości siarki w paliwie można wyznaczyć na podstawie wzoru:

$$E_{SO_2}(P_n) = w_{uSO_2} B(P_n) s \left(1 - \frac{\eta_{IOS}}{100}\right) = w_{uSO_2} s (100 - \eta_{IOS}) \frac{Q_d(P_n)}{W} 10^1 \quad (4.25)$$

gdzie: E_{SO_2} – emisja SO₂ w kg/h; w_{uSO_2} – wskaźnik unosu SO₂ w kg/(Mg·%); η_{IOS} – skuteczność instalacji odsiarczania spalin, %.

W procesie spalania powstaje tlenek, dwutlenek oraz podtlenek azotu. Czynnikiem decydującym o ilości wytworzonych tlenków azotu jest typ paleniska, rodzaj paliwa i sposób jego spalania, temperatura i in. [Jud74]. Zmniejszenie współczynnika nadmiaru powietrza powoduje obniżenie zawartości NO_x . Przy spalaniu paliw w paleniskach kotłowych i przemysłowych ponad 98% węgla zawartego w paliwie ulega zupełnemu spalaniu na CO_2 [Jud74]. Tlenek węgla CO powstaje w procesie niezupełnego spalania, redukcji CO_2 przy przepływie przez warstwy gorącego węgla oraz dysocjacji CO_2 w wysokich temperaturach. Ilość wytworzonego CO zależy istotnie od rodzaju paleniska. Godzinowe emisje NO_x , CO_2 i CO określa się na podstawie wskaźników unosu ze wzorów:

$$E_{NO_x}(P_n) = w_{uNO_x} B(P_n) \left(1 - \frac{\eta_{NO_x}}{100} \right) = w_{uNO_x} (100 - \eta_{NO_x}) \frac{Q_d(P_n)}{W} 10^1 \quad (4.26)$$

$$E_{CO_2}(P_n) = w_{uCO_2} B(P_n) = w_{uCO_2} \frac{Q_d(P_n)}{W} 10^3 \quad (4.27)$$

$$E_{CO}(P_n) = w_{uCO} B(P_n) = w_{uCO} \frac{Q_d(P_n)}{W} 10^3 \quad (4.28)$$

gdzie: E_{NO_x} , E_{CO_2} , E_{CO} – emisje NO_x , CO_2 , CO , kg/h; w_{uNO_x} , w_{uCO_2} , w_{uCO} – wskaźniki unosu NO_x , CO_2 , CO , kg/Mg paliwa; η_{NO_x} – skuteczność instalacji odazotowywania, %.

Wskaźniki unosu lub emisji substancji zanieczyszczających wyznacza się na podstawie specjalistycznych pomiarów i danych technologicznych charakteryzujących obiekt lub przyjmuje się z materiałów informacyjno-instruktażowych Ministerstwa Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa (MOŚZNiL) [MOŚ96].

Dysponując danymi z ciągłych pomiarów emisji zanieczyszczeń można podjąć się aproksymacji poziomu emisji poszczególnych substancji zanieczyszczających $E_y = f(P_n, W, \dots)$. Aproksymator można skonstruować na bazie sieci neuronowej typu wielowarstwowego perceptronu. Składowymi wektorów wejściowych są czynniki i parametry, które w istotny sposób wpływają na wielkość emisji danej substancji zanieczyszczającej. Przykładowo dla emisji pyłu czynnikami takimi są: obciążenie bloku, wartość opałowa paliwa, zawartość popiołu w paliwie, zawartość części palnych w pyle, wilgotność paliwa, temperatura spalania i inne. Doboru składowych wektora wejściowego należy dokonać eksperymentalnie (np. używając metod opisanych w [Dud99a] i [Dud99b]).

Koszty godzinowe związane z emisją zanieczyszczeń oblicza się ze wzoru:

$$K_{ez}(P_n) = \sum_y [E_y(P_n) s_{jy}] \quad (4.29)$$

w którym: K_{ez} – godzinowy koszt emisji zanieczyszczeń do powietrza atmosferycznego, zł/h; y – wskaźnik rodzaju substancji zanieczyszczającej: $y = \{p, SO_2, NO_x, CO_2, CO\}$; E_y – emisja substancji typu y do powietrza atmosferycznego, kg/h; s_{jy} – stawki jednostkowe za

wprowadzanie do atmosfery poszczególnych substancji zanieczyszczających określone w odpowiednim rozporządzeniu Rady Ministrów [DzU99a], zł/kg.

W przypadku przekroczenia dopuszczalnych chwilowych emisji zanieczyszczeń, zdefiniowanych w [DzU98a] jako natężenie przepływu masy substancji zanieczyszczających w kg/h (g/h) lub stężenie substancji zanieczyszczających w gazach odlotowych w mg/m³, zgodnie z [DzU98d] wymierza się kary pieniężne w wysokości dziesięciokrotnej jednostkowej stawki opłat za wprowadzanie zanieczyszczeń do powietrza. Jeśli przekroczenia ograniczeń emisji trwają nieprzerwanie przez trzy kolejne lata, opłatę karną zwiększa się dwukrotnie.

Decyzja określająca rodzaje i dopuszczalne ilości substancji zanieczyszczających wprowadzanych do powietrza, łącznie i osobno dla każdego źródła emisji i emitora, wydawana jest przez organy administracji państwowej stopnia wojewódzkiego [Kuc97]. Wielkość emisji zanieczyszczeń nie może powodować przekroczeń dopuszczalnych stężeń substancji oraz wartości podanych w odpowiednim rozporządzeniu Ministra Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa [DzU98e].

Godzinowe koszty kar związanych z naruszeniem wymagań ochrony środowiska co do godzinowej emisji zanieczyszczeń można wyznaczyć wg wzoru:

$$K_{kez}(P_n) = \sum_y \{ [E_y(P_n) - E_{dy}] s_{jy} k_{k1y} \} \quad (4.30)$$

przy czym:

$$k_{k1y} = \begin{cases} 0 & \text{jeśli } E_y \leq E_{dy} \\ k_{sj1y} & \text{jeśli } E_y > E_{dy} \end{cases} \quad (4.31)$$

gdzie: K_{kez} – godzinowy koszt kar związanych z przekroczeniem godzinowej emisji zanieczyszczeń do powietrza atmosferycznego, zł/h; E_{dy} – dopuszczalna emisja godzinowa poszczególnych substancji zanieczyszczających y określona w decyzji o dopuszczalnej emisji, kg/h; k_{sj1y} – krotność stawki jednostkowej do naliczania kar w przypadku przekroczenia poziomu dopuszczalnej emisji godzinowej substancji typu y .

W [DzU98a] mówi się także o dopuszczalnych rocznych ilościach substancji zanieczyszczających wprowadzanych do powietrza, ale uwzględnienie ich w modelu krótkoterminowej optymalizacji pracy elektrowni, a konkretnie w charakterystykach kosztów zmiennych stwarza problemy. Ilości te, charakteryzujące ekonomikę pracy elektrowni, należałoby uwzględnić raczej w modelach optymalizacyjnych o dłuższym (np. rocznym) horyzoncie optymalizacji; model taki zaproponowano w [Brz95a]. Ponadto po zaistnieniu faktu przekroczenia dopuszczalnych ilości rocznych, często podejmuje się decyzję o wstrzymaniu produkcji i zamknięciu zakładu.

Produktem odpadowym spalania powstającym w procesie wytwarzania energii elektrycznej w elektrowniach węglowych jest popiół i żużel. Ilość odpadów paleniskowych zależy od rodzaju i jakości węgla, głównie od zawartości popiołu. Odpady te składowane są

na składowiskach i w pewnej ilości wykorzystywane w przemyśle budowlanym. Odpadami z paleniska fluidalnego są: popiół i sorbent zużyty do odsiarczania spalin.

Strumień masy odpadów paleniskowych powstających w procesie produkcji energii elektrycznej proponuje się określać wg wzoru:

$$m_{op}(P_n) = w_{op} B(P_n) P = w_{op} P \frac{Q_d(P_n)}{W} 10^3 \quad (4.32)$$

gdzie: m_{op} – ilość odpadów paleniskowych powstałych w procesie spalania, Mg/h;
 w_{op} – wskaźnik ilości odpadów paleniskowych wyznaczony wg wzoru (4.34), Mg/(Mg·%).

W blokach energetycznych wyposażonych w IOS z technologią pól suchą odpadem jest mieszanina popiołu i produktów odsiarczania spalin, którą składa się na składowiskach lub wykorzystuje do kształtowania i niwelacji terenu, budowy nasypów drogowych itp. [Kuc97]. Odpadem z mokrej IOS jest gips dwuwodny, który może być wykorzystany do produkcji gipsu budowlanego lub odłożony na składowisku.

Strumień masy odpadów z IOS można obliczyć ze wzoru:

$$m_{oIOS}(P_n) = w_{oIOS} B(P_n) S = w_{oIOS} S \frac{Q_d(P_n)}{W} 10^3 \quad (4.33)$$

gdzie: m_{oIOS} – ilość odpadów z IOS, Mg/h; w_{oIOS} – wskaźnik ilości odpadów z IOS wyznaczony wg wzoru (4.35), Mg/(Mg·%).

Wskaźniki ilości odpadów można wyznaczyć szacunkowo na podstawie danych z przeszłości:

$$w_{op} = \frac{M_{op} \bar{W}}{Q_{d\Sigma} \bar{P}} 10^{-3} \quad (4.34)$$

$$w_{oIOS} = \frac{M_{oIOS} \bar{W}}{Q_{d\Sigma IOS} \bar{S}} 10^{-3} \quad (4.35)$$

gdzie: M_{op} , M_{oIOS} – całkowita masa odpadów paleniskowych oraz odpadów z IOS powstałych w okresie T_a (np. miesiąc, rok), Mg; $Q_{d\Sigma}$ – całkowita energia chemiczna paliwa zużytego w okresie T_a , GJ; $Q_{d\Sigma IOS}$ – całkowita energia chemiczna paliwa zużytego w blokach z IOS w okresie T_a , GJ; \bar{W} – średnia wartość opałowa paliwa w okresie T_a , kJ/kg; \bar{P} – średnia zawartość popiołu w paliwie w okresie T_a , %.

Opłata za składowanie odpadów obejmuje:

- opłatę za umieszczenie odpadów na składowisku wg stawek określonych w odpowiednim rozporządzeniu Rady Ministrów [DzU99b] oraz
- opłatę za każdy rok ich składowania, równą 3% opłaty za umieszczenie na składowisku w odniesieniu do 12 miesięcznego okresu składowania.

Oplaty za składowanie odpadów umieszczonych raz na składowisku płaci się corocznie do czasu zakończenia eksploatacji składowiska lub jego wydzielonej części i wykonania prac rekultywacyjnych. W przypadku sprzedaży popiołu i żużla oraz gipsu z IOS do celów budowlanych uzyskane zyski pomniejszają koszty składowania odpadów.

Koszty godzinowe składowania powstałych odpadów można wyznaczyć następująco:

$$K_{so}(P_n) = m_{op}(P_n)k_{o1p}s_{jop}(1 + r_{so}l_{op}) + m_{oIOS}(P_n)k_{o1IOS}s_{joIOS}(1 + r_{so}l_{oIOS}) + \\ - m_{op}(P_n)k_{o2p}c_{jop} - m_{oIOS}(P_n)k_{o2IOS}c_{joIOS} \quad (4.36)$$

gdzie: K_{so} – godzinowy koszt składowania odpadów, zł/h; k_{o1p} , k_{o1IOS} – współczynniki określające jaka część odpadów paleniskowych i odpadów z IOS składowana jest na składowisku ($0 \leq k_{o1p}, k_{o1IOS} \leq 1$); k_{o2p} , k_{o2IOS} – współczynniki określające jaka część odpadów paleniskowych i odpadów z IOS jest sprzedawana ($0 \leq k_{o2p}, k_{o2IOS} \leq 1$); s_{jop} , s_{joIOS} – stawka jednostkowa za umieszczenie odpadów paleniskowych lub odpadów z IOS na składowisku w zł/Mg; r_{so} – odsetek opłaty za umieszczenie odpadów na składowisku, potrzebny do naliczania opłaty rocznej za ich składowanie (obecnie 3%); l_{op} , l_{oIOS} – przewidywany okres składowania odpadów paleniskowych i odpadów z IOS, a; c_{jop} , c_{joIOS} – średnia cena jednostkowa sprzedaży odpadów paleniskowych i odpadów z IOS, zł/Mg.

Koszty związane z bezpowrotnym zużyciem wody powierzchniowej w procesie wytwarzania energii elektrycznej oraz wody pobieranej z miejskiej sieci wodociągowej uwzględniono w kosztach zużycia materiałów dodatkowych (4.16). Stawki jednostkowe za pobór wody do celów produkcyjnych określone są w odpowiednich rozporządzeniach Rady Ministrów ([DzU93] z późniejszymi zmianami). Bezwrotne straty wody powstają w wyniku parowania wody chłodzącej i są większe w zamkniętych obiegach chłodzenia. Zapotrzebowanie na wodę ruchową, wykorzystywaną do chłodzenia łożysk pomp, silników, wentylatorów, transformatorów oraz do chłodzenia oleju i innych urządzeń, kształtuje się na poziomie od 3 do 5% ilości wody chłodzącej. Woda dodatkowa uzupełnia straty wody w obiegu parowo – wodnym powstające w wyniku odmulania, odsalania i przecieków instalacji.

Ścieki z elektrowni są zanieczyszczone ciepłem, substancjami rozpuszczonymi (tzw. ścieki zasolone), zawiesiną oraz produktami ropy naftowej [Kuc97]. Władze wodne zwykle stawiają warunek, aby ścieki z elektrowni po oczyszczeniu odpowiadały II klasie czystości wód. Oplaty za ścieki wymierzane są w zależności od ich rodzaju oraz zawartości ładunku zanieczyszczeń. Wskaźnikami zanieczyszczenia są: BZT₅ – 5-dniowe biochemiczne zapotrzebowanie na tlen, ChZT – chemiczne zapotrzebowanie na tlen określane metodą dwuchromianową, zawiesina ogólna, suma jonów chlorków i siarczanów, suma metali ciężkich oraz fenole lotne [DzU93]. Oplatę za ścieki nalicza się na podstawie rozporządzeń Rady Ministrów. Przy jej ustalaniu przyjmuje się ten wskaźnik zanieczyszczenia (BZT₅, ChZT, zawiesina, suma jonów chlorków i siarczanów), za który opłata jest największa. Oplatę za wprowadzanie zasolonych ścieków z IOS ustala się za sumę jonów chlorków i siarczanów. Do tak ustalonej opłaty dolicza się opłatę za sumę metali ciężkich i fenole lotne. Koszty

godzinowe związane z odprowadzaniem ścieków do wód proponuje się określać w uproszczony sposób ze wzoru:

$$\begin{aligned} K_{\dot{s}}(P_n) &= w_{\dot{s}} B(P_n) \left[(1 - k_{\dot{s}}) w_{z\dot{s}} s_{jz} + k_{\dot{s}} w_{zjcs} s_{jjcs} + w_{zmc} s_{jmc} + w_{zfl} s_{jfl} \right] \cdot 10^{-3} = \\ &= w_{\dot{s}} \frac{Q_d(P_n)}{W} \left[(1 - k_{\dot{s}}) w_{z\dot{s}} s_{jz} + k_{\dot{s}} w_{zjcs} s_{jjcs} + w_{zmc} s_{jmc} + w_{zfl} s_{jfl} \right] \end{aligned} \quad (4.37)$$

gdzie: $K_{\dot{s}}$ – godzinowy koszt odprowadzania ścieków, zł/h; $w_{\dot{s}}$ – wskaźnik ogólnej ilości ścieków na tonę spalanej w kotle paliwa, m³/Mg paliwa; $k_{\dot{s}}$ – współczynnik określający jaką część ścieków stanowią zasolone ścieki z IOS ($0 \leq k_{\dot{s}} \leq 1$); $w_{z\dot{s}}$ – wskaźnik ładunku zanieczyszczenia, dla którego opłata jest największa: BZT₅, ChZT, zawiesina, suma jonów chlorków i siarczanów, mg/dm³ ścieków; s_{jz} – stawka opłaty za 1 kg ładunku wyrażonego w BZT₅, ChZT, za 1 kg zawiesiny ogólnej lub za 1kg sumy jonów chlorków i siarczanów w zł/kg; w_{zjcs} – wskaźnik zanieczyszczenia w postaci ładunku sumy jonów chlorków i siarczanów, mg/dm³ ścieków; s_{jjcs} – stawka opłaty za 1 kg ładunku sumy jonów chlorków i siarczanów, zł/kg; w_{zmc} – wskaźnik zanieczyszczenia w postaci ładunku sumy metali ciężkich, mg/dm³ ścieków; s_{jmc} – stawka opłaty za 1 kg ładunku sumy metali ciężkich, zł/kg; w_{zfl} – wskaźnik zanieczyszczenia w postaci ładunku fenoli lotnych, mg/dm³ ścieków; s_{jfl} – stawka opłaty za 1 kg ładunku fenoli lotnych, zł/kg.

Wyżej wymienione wskaźniki wyznacza się na podstawie danych eksploatacyjnych, pomiarów i analiz chemicznych ścieków.

4.3.3. KONSTRUKCJA CHARAKTERYSTYK KOSZTÓW ZMIENNYCH

Charakterystykę kosztów zmiennych zależnych od obciążenia JW proponuje się zdefiniować wzorem:

$$\begin{aligned} K_z(P_n) &= K_p(P_n) + K_{md}(P_n) + K_{meIOS}(P_n) + K_{meNO_x}(P_n) + K_{ez}(P_n) + K_{kez}(P_n) + \\ &+ K_{so}(P_n) + K_{\dot{s}}(P_n) \end{aligned} \quad (4.38)$$

Wykorzystując wyżej zamieszczone zależności otrzymujemy rozwiniętą postać wzoru (4.38):

$$\begin{aligned} K_z(P_n) &= \frac{Q_d(P_n)}{W} \left\{ c_{jzp} + c_{jtp} + \sum_x (w_{zx} c_{jx}) + w_{zs} c_{js} + w_{zwIOS} c_{jw} + w_{zNH_3} c_{jNH_3} + w_{zkat} p c_{jkat} + \right. \\ &+ w_{up} p \frac{100 - \eta_{odp}}{100 - c_p} (1 + k_{k1p}) s_{jp} + w_{uSO_2} s (100 - \eta_{IOS}) (1 + k_{k1SO_2}) s_{jSO_2} \cdot 10^{-2} + \\ &+ w_{uNO_x} (100 - \eta_{NO_x}) (1 + k_{k1NO_x}) s_{jNO_x} \cdot 10^{-2} + w_{uCO_2} (1 + k_{k1CO_2}) s_{jCO_2} + w_{uCO} (1 + k_{k1CO}) s_{jCO} + \\ &+ w_{op} p \left[k_{o1p} (1 + r_{so} l_{op}) s_{jop} - k_{o2p} c_{jop} \right] + w_{oIOS} s \left[k_{oIOS} (1 + r_{so} l_{oIOS}) s_{joIOS} - k_{o2IOS} c_{joIOS} \right] + \end{aligned}$$

$$+ w_s \left[(1 - k_s) w_{zs} s_{jz} + k_s w_{zjcs} s_{jjcs} + w_{zmc} s_{jmc} + w_{zfl} s_{jfl} \right] \cdot 10^{-3} \left. \right\} \cdot 10^3 - \sum_y E_{dy} k_{k1y} s_{jy} \quad (4.39)$$

W powyższym wzorze należy podstawić: $w_{zs} = 0$, $w_{zwIOS} = 0$, $\eta_{IOS} = 0$, $w_{oIOS} = 0$, $k_s = 0$, jeśli blok nie posiada IOS oraz: $w_{zNH_3} = 0$, $w_{zkat} = 0$, $\eta_{NO_x} = 0$, jeśli blok nie posiada instalacji odazotowywania spalin.

Do konstrukcji rzeczywistych charakterystyk kosztów zmiennych wykorzystano dane z elektrowni zestawione w dodatku 3. Charakterystyki te określono dla każdego bloku energetycznego ze wzoru (4.39) z uwagami zamieszczonymi w dodatku 4. Charakterystyki kosztów zmiennych bloków energetycznych w formie tabelarycznej zamieszczono w dodatku 5. Charakterystyki aproksymowano do celów numerycznych obliczeń optymalizacyjnych. Pominięto przy tym wszelkie punkty nieciągłości i załamania charakterystyk (moc ekonomiczna modelowanych bloków pokrywa się z mocą osiągalną P_{max}). W celu wyboru wyrażenia analitycznego, które najlepiej przybliży charakterystyki tabelaryczne, zbadano dokładność aproksymacji za pomocą: funkcji liniowej, wielomianu drugiego stopnia, wielomianu trzeciego stopnia i sieci neuronowej typu dwuwarstwowego perceptronu z jednym („perceptron 1”) lub dwoma („perceptron 2”) neuronami sigmoidalnymi bipolarnymi w warstwie ukrytej oraz neuronem liniowym w warstwie wyjściowej (doświadczalnie stwierdzono, że większa liczba neuronów ukrytych prowadzi do wzrostu błędu generalizacji sieci). Sieć uczono metodą Levenberga – Marquardta [Oso96], która zapewnia szybszą zbieżność algorytmu w stosunku do klasycznej metody wstecznej propagacji błędu. Wartości wejściowe sieci P_n oraz wartości pożądaných odpowiedzi K_z przeskalowano na przedział $\langle -0,9, 0,9 \rangle$. Sieci uczono 1500 epok.

W zadaniu aproksymacji minimalizowano kryterium najmniejszych kwadratów. Jako kryterium aproksymacji użyto procentowego, absolutnego błędu względnego postaci:

$$\delta_k = \frac{|K_{zk} - \widehat{K}_{zk}|}{K_{zk}} 100\% \quad (4.40)$$

gdzie: k – indeks punktu charakterystyki tabelarycznej; K_{zk} – koszty zmienne z charakterystyki tabelarycznej, zł/h; \widehat{K}_{zk} – koszty zmienne aproksymowane w punkcie k , zł/h.

W celu oceny funkcji aproksymujących, aproksymacji dokonano w oparciu o punkty 1, 3, 5 i 7 charakterystyk tabelarycznych, określając błędy średnie:

$$\delta_a = \frac{1}{4} \sum_{k=1,3,5,7} \delta_k \quad (4.41)$$

Następnie wyznaczono błędy dla punktów 2, 4 i 6:

$$\delta_b = \frac{1}{3} \sum_{k=2,4,6} \delta_k \quad (4.42)$$

Wyniki zestawiono w tabelicy 4.2.

Tablica 4.2. Błędy aproksymacji charakterystyk kosztów zmiennych bloków w %. Źródło: opracowanie własne.

Blok nr	Aproksymator									
	Funkcja liniowa		Wielomian II-go stopnia		Wielomian III-go stopnia		Perceptron 1		Perceptron 2	
	δ_a	δ_b	δ_a	δ_b	δ_a	δ_b	δ_a	δ_b	δ_a	δ_b
1	0,4709	0,2689	0,0790	0,1119	$3,07 \cdot 10^{-14}$	$1,68 \cdot 10^{-3}$	0,0767	0,1073	0,0767	0,1073
2	0,4732	0,2724	0,0790	0,1128	$2,55 \cdot 10^{-14}$	$1,23 \cdot 10^{-3}$	0,0768	0,1083	$3,16 \cdot 10^{-6}$	0,1277
3	0,4791	0,2756	0,0799	0,1124	$2,43 \cdot 10^{-14}$	$1,48 \cdot 10^{-3}$	0,0775	0,1077	0,0774	0,1075
4	0,4922	0,2814	0,0823	0,1166	$1,94 \cdot 10^{-14}$	$1,67 \cdot 10^{-3}$	0,0797	0,1114	0,0002	0,1020
5	0,4480	0,2580	0,0742	0,1061	$1,88 \cdot 10^{-14}$	$4,07 \cdot 10^{-4}$	0,0724	0,1023	0,0723	0,1022
6	0,4748	0,2723	0,0788	0,1124	$3,58 \cdot 10^{-14}$	$9,01 \cdot 10^{-4}$	0,0765	0,1078	0,0765	0,1076
7	0,4408	0,2528	0,0744	0,1055	$2,93 \cdot 10^{-14}$	$6,72 \cdot 10^{-4}$	0,0726	0,1018	0,0726	0,1018
8	0,4367	0,2272	0,0731	0,0855	$2,30 \cdot 10^{-14}$	$2,35 \cdot 10^{-2}$	0,0715	0,0846	0,0714	0,0846
9	0,4751	0,2722	0,0799	0,1124	$1,88 \cdot 10^{-14}$	$1,58 \cdot 10^{-3}$	0,0776	0,1078	0,0776	0,1076
10	0,4382	0,2514	0,0729	0,1041	$1,94 \cdot 10^{-14}$	$8,89 \cdot 10^{-4}$	0,0712	0,1006	0,0711	0,1004
11	0,4367	0,2516	0,0728	0,1037	$1,10 \cdot 10^{-14}$	$1,54 \cdot 10^{-3}$	0,0712	0,1002	0,0711	0,1000
12	0,4455	0,2548	0,0743	0,1064	$9,86 \cdot 10^{-15}$	$1,27 \cdot 10^{-3}$	0,0725	0,1027	0,0724	0,1025
Błąd średni	0,4593	0,2615	0,0767	0,1075	$2,21 \cdot 10^{-14}$	$3,07 \cdot 10^{-3}$	0,0747	0,1035	0,0616	0,1043

Do aproksymacji zastosowano też sieć funkcyjną [Pao89], która często wykazuje lepsze działanie od perceptronu, posiada prostszą architekturę (zwykle jedną warstwę przetwarzającą) i charakteryzuje się szybszą zbieżnością. Sieć funkcyjna posiada dodatkowe wejścia będące funkcjami składowych oryginalnego wektora wejściowego. Zastosowano rozszerzenia typu $\sin(\pi P_n)$ oraz $\cos(\pi P_n)$ i jedną lub dwie warstwy neuronów. Sieć uczono metodą Levenberga – Marquardta. We wszystkich przypadkach sieć wykazywała słabsze działanie od perceptronu. Najlepszy rezultaty jakie udało się uzyskać to: $\delta_b = 0,2724\%$, przy architekturze: jedno rozszerzenie funkcyjne $\sin(\pi P_n)$ oraz jeden neuron liniowy, $\delta_b = 0,2350\%$, przy architekturze: dwa rozszerzenia funkcyjne $\sin(\pi P_n)$ i $\cos(\pi P_n)$ oraz jeden neuron liniowy.


Najmniejsze błędy wykazała aproksymacja charakterystyk kosztów zmiennych wielomianem III-go stopnia ($\bar{\delta}_b = 3,07 \cdot 10^{-3}$). W tym przypadku jednak charakterystyki nie są wypukłe w całym zakresie $\langle P_{n\text{mini}}, P_{n\text{maxi}} \rangle$, co uniemożliwia stosowanie ERO według równych przyrostów względnych kosztów zmiennych. Do aproksymacji przyjęto wielomian II-go stopnia: $K_z(P_n) = w_a P_n^2 + w_b P_n + w_c$, co jest powszechnie stosowane w praktyce i zapewnia dostateczną dokładność. Współczynniki wielomianu oraz błędy aproksymacji charakterystyk

wyznaczonych w oparciu o wszystkie punkty charakterystyk tabelarycznych ($k = 1, 2, \dots, 7$) zamieszczono w tablicy 4.3. Aproksymowane charakterystyki kosztów zmiennych pokazano na rys. 4.3.

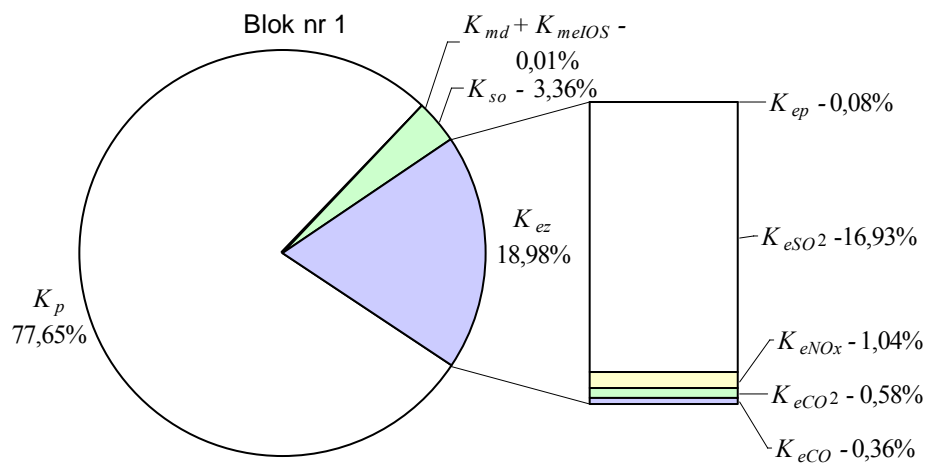
Tablica 4.3. Współczynniki wielomianów II-go stopnia aproksymujących charakterystyki kosztów zmiennych oraz błędy aproksymacji w %. Źródło: opracowanie własne.

Blok nr	Współczynniki wielomianu II-go stopnia			Błędy aproksymacji
	w_a	w_b	w_c	
1	$1,812482 \cdot 10^{-2}$	29,5871	2572,95	$9,37 \cdot 10^{-2}$
2	$1,873226 \cdot 10^{-2}$	30,2515	2665,09	$9,42 \cdot 10^{-2}$
3	$1,883362 \cdot 10^{-2}$	29,9069	2691,08	$9,44 \cdot 10^{-2}$
4	$1,951954 \cdot 10^{-2}$	29,8966	2746,34	$9,76 \cdot 10^{-2}$
5	$1,685515 \cdot 10^{-2}$	29,1981	2406,11	$8,85 \cdot 10^{-2}$
6	$1,832903 \cdot 10^{-2}$	29,2408	2567,95	$9,37 \cdot 10^{-2}$
7	$1,706769 \cdot 10^{-2}$	30,1974	2436,28	$8,83 \cdot 10^{-2}$
8	$1,428946 \cdot 10^{-2}$	26,6310	2126,52	$7,61 \cdot 10^{-2}$
9	$1,915294 \cdot 10^{-2}$	30,8735	2713,62	$9,44 \cdot 10^{-2}$
10	$1,394171 \cdot 10^{-2}$	24,8460	2014,39	$8,68 \cdot 10^{-2}$
11	$1,463057 \cdot 10^{-2}$	26,1969	2112,74	$8,67 \cdot 10^{-2}$
12	$1,468215 \cdot 10^{-2}$	25,6548	2111,26	$8,86 \cdot 10^{-2}$


Charakterystyki kosztów zmiennych rozdzielone są na dwa pasma: górne – obejmujące charakterystyki bloków bez IOS i dolne – charakterystyki bloków wyposażonych w IOS (bloki nr 8, 10, 11 i 12). Średnie koszty zmienne bloków w paśmie górnym są o 19% wyższe od średnich kosztów bloków w paśmie dolnym. Oznacza to, że w modelowanej elektrowni IOS pozwala uzyskać dobowe oszczędności od 35 do 60 tys. zł/blok, zależnie od obciążenia bloku. Strukturę kosztów zmiennych wytwarzania dla bloku bez IOS (blok nr 1) zobrazowano na rys. 4.4, natomiast dla bloku z IOS (blok nr 10) – na rys. 4.5.



Rys. 4.3. Charakterystyki kosztów zmiennych modelowanych bloków energetycznych.
Źródło: opracowanie własne.



Rys. 4.4. Struktura kosztów zmiennych bloku bez IOS (blok nr 1). Źródło: oprac. własne.



Rys. 4.5. Struktura kosztów zmiennych bloku z IOS (blok nr 10). Źródło: oprac. własne.

Instalacja odsiarczania gazów odlotowych pozwala zredukować koszty emisji zanieczyszczeń średnio z 18 do 4% całkowitych kosztów zmiennych bloku, przy czym pojawiają się koszty materiałów eksploatacyjnych IOS (ok. 2,4% całkowitych kosztów zmiennych) oraz wzrastają koszty składowania odpadów z 3,4 do 4,2% całkowitych kosztów zmiennych.

Jeśli moc osiągalna bloku P_{nmax} różni się od mocy ekonomicznej P_{ne} , charakterystykę kosztów zmiennych proponuje się aproksymować funkcją:


$$K_z(P_n) = \begin{cases} w_{a1}P_n^2 + w_{b1}P_n + w_{c1} & \text{dla } P_{nmin} \leq P_n \leq P_{ne} \\ w_{a2}P_n^2 + w_{b2}P_n + w_{c2} & \text{dla } P_{ne} < P_n \leq P_{nmax} \end{cases} \quad (4.43)$$

gdzie: w_{a1} , w_{b1} , w_{c1} , w_{a2} , w_{b2} , w_{c2} – współczynniki.

Charakterystyki przyrostów względnych strumienia kosztów zmiennych, w przypadku aproksymacji charakterystyk $K_z(P_n)$ wielomianem II-go stopnia, przyjmują postać:

$$\varepsilon_k(P_n) = \frac{dK_z}{dP_n} = w_a P_n + w_b \quad P_{nmin} \leq P_n \leq P_{nmax} \quad (4.44)$$

Charakterystyki te pokazano na rys. 4.6.



Rys. 4.6. Charakterystyki przyrostów względnych strumienia kosztów zmiennych modelowanych bloków energetycznych. Źródło: opracowanie własne.

Jeśli przyrost względny, z jakim pracuje elektrownia jest mniejszy od minimalnego przyrostu bloku, blok pracuje przy minimum technicznym. Podobnie, jeśli przyrost jest większy od maksymalnego przyrostu bloku, pracuje on z obciążeniem osiągalnym. Obciążenia jednostek w zależności od zadanego przyrostu względnego odczytuje się z charakterystyk $P_n = f(\varepsilon_k)$:

$$P_n(\varepsilon_k) = \begin{cases} P_{n\min}, & \text{dla } \varepsilon_k < \varepsilon_k(P_{n\min}) \\ P_{n\max}, & \text{dla } \varepsilon_k > \varepsilon_k(P_{n\max}) \\ \frac{\varepsilon_k - w_b}{w_a}, & \text{dla } \varepsilon_k(P_{n\min}) \leq \varepsilon_k \leq \varepsilon_k(P_{n\max}) \end{cases} \quad (4.45)$$

4.3.4. KONSTRUKCJA CHARAKTERYSTYK KOSZTÓW ROZRUCHÓW

Praca przerywana bloku powoduje wzrost kosztu wytwarzania wywołany głównie zwiększonym zużyciem paliwa rozpałowego i podstawowego na pokrycie strat rozruchowych. W modelu, oprócz kosztów paliwa, uwzględnia się koszt wody dodatkowej, koszty emisji zanieczyszczeń, koszty eksploatacji IOS i instalacji odazotowywania spalin, koszty składowania odpadów i odprowadzania ścieków powstałych podczas rozruchu oraz koszty remontów i przeglądów spowodowanych częstymi rozruchami. Charakterystyki kosztów rozruchu bloku można wyznaczyć na bazie charakterystyk strat rozruchowych $Q_r = f(t_p)$ (charakterystyki te opisano w dodatku 1) ze wzoru:

$$K_r(t_p) = \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} (c_{jzp} + c_{jtp}) \cdot 10^3 + \frac{Q_{rr}(t_p)}{W_r} (c_{jzr} + c_{jtr}) \cdot 10^3 + \quad (4.46)$$

$$+ K_{wdr}(t_p) + K_{erIOS}(t_p) + K_{erNO_x}(t_p) + K_{ezr}(t_p) + K_{sor}(t_p) + K_{sr}(t_p) + K_{ur}$$

gdzie: $Q_r(t_p)$ – straty rozruchowe energii po czasie postoju bloku w rezerwie równym t_p , GJ; $Q_{rr}(t_p)$ – energia chemiczna paliwa rozpałowego doprowadzona do bloku w cyklu odstawienie – rozruch po czasie postoju t_p , GJ; c_{jzp} , c_{jtp} – odpowiednio cena jednostkowa zakupu paliwa podstawowego i opłata jednostkowa za jego transport do elektrowni, zł/Mg; c_{jzr} , c_{jtr} – odpowiednio cena jednostkowa zakupu paliwa rozpałowego i opłata jednostkowa za jego transport do elektrowni, zł/Mg; W , W_r – wartość opałowa paliwa podstawowego i rozpałowego, kJ/kg; $K_{wdr}(t_p)$ – koszt wody dodatkowej na pokrycie strat wody w cyklu odstawienie – rozruch po czasie postoju t_p , szacowany na podstawie zużycia wody $z_{wdr}(t_p)$ odczytanego z liczników: $K_{wdr}(t_p) = z_{wdr}(t_p)c_{jw}$, zł; $K_{erIOS}(t_p)$, $K_{erNO_x}(t_p)$ – koszty eksploatacyjne instalacji odsiarczania i odazotowywania spalin powstałych podczas rozruchu po czasie postoju t_p , zł; $K_{ezr}(t_p)$ – koszt emisji substancji zanieczyszczających podczas rozruchu po czasie postoju t_p , zł; $K_{sor}(t_p)$, $K_{sr}(t_p)$ – koszt składowania odpadów i odprowadzania ścieków powstałych podczas rozruchu po czasie postoju t_p ; zł; K_{ur} – wzrost kosztów remontów, konserwacji i przeglądów wskutek częstych odstawień i uruchomień, zł.

Koszty eksploatacyjne instalacji odsiarczania spalin powstałych podczas rozruchu można określić ze wzoru:

$$K_{erIOS}(t_p) = m_{sr}(t_p)c_{js} + z_{wrIOS}(t_p)c_{jw} + A_{rIOS}(t_p)c_{jMWh} \quad (4.47)$$

gdzie:

$$m_{sr}(t_p) = w_{zs}B_p(t_p)s + w_{zsr}B_r(t_p)s_r = \left[w_{zs}s \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + w_{zsr}s_r \frac{Q_{rr}(t_p)}{W_r} \right] \cdot 10^3 \quad (4.48)$$

$m_{sr}(t_p)$ – masa sorbentu zużytego w IOS podczas rozruchu po czasie postoju t_p , Mg;
 w_{zsr} – wskaźnik zużycia sorbentu w IOS dla paliwa rozpałowego w Mg/(Mg·%), określane na podstawie badań i danych producenta instalacji; $B_p(t_p)$, $B_r(t_p)$ – odpowiednio, całkowite zużycie paliwa podstawowego i rozpałowego w trakcie rozruchu po czasie postoju t_p , Mg;
 s_r – procentowa zawartość siarki w paliwie rozpałowym, %; $z_{wrIOS}(t_p)$ – zużycie wody w IOS podczas rozruchu po czasie postoju t_p , szacowane na podstawie odczytu z liczników lub danych producenta IOS, m³; $A_{rIOS}(t_p)$ – energia elektryczna zużywana w IOS w trakcie rozruchu po czasie postoju t_p , określana na podstawie odczytu z liczników lub danych producenta IOS, MW·h; c_{jMWh} – cena jednostki energii elektrycznej, zł/(MW·h); pozostałe oznaczenia jak we wzorach (4.18) ÷ (4.20).

Wzór określający koszty eksploatacyjne instalacji odazotowywania spalin powstałych podczas rozruch przyjmuje postać:

$$K_{erNO_x}(t_p) = z_{rNH_3}(t_p)c_{jNH_3} + z_{rkat}(t_p)c_{jkat} + A_{rNO_x}(t_p)c_{jMWh} \quad (4.49)$$

gdzie:

$$z_{rkat}(t_p) = w_{zkat} B_p(P_n) p = w_{zkat} p \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^3 \quad (4.50)$$

$z_{rNH_3}(t_p)$ – całkowite zużycie amoniaku w instalacji odazotowywania spalin podczas rozruchu po czasie postoju t_p , szacowane na podstawie danych producenta instalacji, m³;
 $z_{rkat}(t_p)$ – całkowite zużycie katalizatora w instalacji z selektywną redukcją katalityczną podczas rozruchu po czasie postoju t_p , m³; $A_{rNO_x}(t_p)$ – energia elektryczna zużywana w instalacji odazotowywania spalin w trakcie rozruchu po czasie postoju t_p , określana na podstawie odczytu z liczników lub danych producenta instalacji, MW·h; pozostałe oznaczenia jak we wzorach (4.22) i (4.23).

Koszty związane z emisją zanieczyszczeń zależą od ładunku substancji zanieczyszczających wprowadzanych do powietrza podczas rozruchu:

$$K_{ezr}(t_p) = \sum_y [E_{py}(t_p) + E_{ry}(t_p)] s_{jy} \quad (4.51)$$

gdzie: $E_{py}(t_p)$ – całkowita emisja poszczególnych substancji zanieczyszczających y powstałych ze spalania paliwa podstawowego podczas rozruchu po czasie postoju t_p , kg;
 $E_{ry}(t_p)$ – całkowita emisja poszczególnych substancji zanieczyszczających y powstałych ze spalania paliwa rozpałowego podczas rozruchu po czasie postoju t_p , kg.

Emisje zanieczyszczeń ze spalania paliwa podstawowego podczas rozruchu można określić ze wzorów podobnych do (4.24) ÷ (4.28), podstawiając zamiast strumienia energii chemicznej paliwa $Q_d(P_n)$ straty rozruchowe energii pokryte przez paliwo podstawowe:

$$E_{pp}(t_p) = w_{up} B_p(t_p) \frac{p}{\left(1 - \frac{c_p}{100}\right)} \left(1 - \frac{\eta_{odp}}{100}\right) = w_{up} [Q_r(t_p) - Q_{rr}(t_p)] \frac{p(100 - \eta_{odp})}{W(100 - c_p)} 10^3 \quad (4.52)$$

$$E_{pSO_2}(t_p) = w_{uSO_2} B_p(t_p) s \left(1 - \frac{\eta_{IOS}}{100}\right) = w_{uSO_2} s (100 - \eta_{IOS}) \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^1 \quad (4.53)$$

$$E_{pNO_x}(t_p) = w_{uNO_x} B_p(t_p) \left(1 - \frac{\eta_{NO_x}}{100}\right) = w_{uNO_x} (100 - \eta_{NO_x}) \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^1 \quad (4.54)$$

$$E_{pCO_2}(t_p) = w_{uCO_2} B_p(t_p) = w_{uCO_2} \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^3 \quad (4.55)$$

$$E_{pCO}(t_p) = w_{uCO} B_p(t_p) = w_{uCO} \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^3 \quad (4.56)$$

gdzie: $E_{pp}(t_p)$, $E_{pSO_2}(t_p)$, $E_{pNO_x}(t_p)$, $E_{pCO_2}(t_p)$, $E_{pCO}(t_p)$ – emisje pyłu, SO₂, NO_x, CO₂ i CO ze spalania paliwa podstawowego w trakcie rozruchu po czasie postoju t_p , kg.

Analogicznie można określić emisje zanieczyszczeń podczas rozruchu ze spalania paliwa rozpałowego w postaci oleju opałowego lub gazu. Ładunki pyłu, SO₂, NO_x, CO₂ oraz CO ze spalania mazutu podczas rozruchu proponuje się obliczać ze wzorów:

$$E_{rp}(t_p) = w_{urp} B_r(t_p) \left(1 - \frac{\eta_{odp}}{100}\right) = w_{urp} (100 - \eta_{odp}) \frac{Q_{rr}(t_p)}{W_r \rho_r} 10^1 \quad (4.57)$$

$$E_{rSO_2}(t_p) = w_{urSO_2} B_r(t_p) s_r \left(1 - \frac{\eta_{IOS}}{100}\right) = w_{urSO_2} s_r (100 - \eta_{IOS}) \frac{Q_{rr}(t_p)}{W_r \rho_r} 10^1 \quad (4.58)$$

$$E_{rNO_x}(t_p) = w_{urNO_x} B_r(t_p) \left(1 - \frac{\eta_{NO_x}}{100}\right) = w_{urNO_x} (100 - \eta_{NO_x}) \frac{Q_{rr}(t_p)}{W_r \rho_r} 10^1 \quad (4.59)$$

$$E_{rCO_2}(t_p) = w_{urCO_2} B_r(t_p) = w_{urCO_2} \frac{Q_{rr}(t_p)}{W_r \rho_r} 10^3 \quad (4.60)$$

$$E_{rCO}(t_p) = w_{urCO} B_r(t_p) = w_{urCO} \frac{Q_{rr}(t_p)}{W_r \rho_r} 10^3 \quad (4.61)$$

gdzie: $E_{rp}(t_p)$, $E_{rSO_2}(t_p)$, $E_{rNO_x}(t_p)$, $E_{rCO_2}(t_p)$, $E_{rCO}(t_p)$ – emisje pyłu, SO₂, NO_x, CO₂ i CO ze spalania mazutu w trakcie rozruchu po czasie postoju t_p , kg; w_{urp} , w_{urSO_2} , w_{urNO_x} , w_{urCO_2} , w_{urCO} – wskaźniki unosu ze spalania mazutu, określane na podstawie pomiarów lub materiałów MOŚZNiL [MOŚ96] w kg/m³ lub kg/(m³·%); ρ_r – gęstość masy mazutu, g/cm³.

Zgodnie z [DzU98e] przy wyznaczaniu przekroczeń dopuszczalnych ilości substancji zanieczyszczających nie uwzględnia się ilości substancji wprowadzonych do powietrza w okresach: „osiągania obciążenia źródła określonego przez producenta, przy którym może ono pracować, prób rozruchowych źródła lub urządzenia ochronnego, dochodzenia do pełnej

zdolności produkcyjnej”. Stąd w modelu pomija się opłaty karne za przekroczenia dopuszczalnych ilości substancji zanieczyszczających podczas rozruchów bloków.

Koszty składowania odpadów paleniskowych i odpadów z IOS powstałych podczas rozruchu szacunkowo można określić ze wzoru:

$$K_{sor}(t_p) = m_{opr}(t_p)k_{o1p}s_{jop}(1+r_{so}l_{op}) + m_{orIOS}(t_p)k_{o1IOS}s_{joIOS}(1+r_{so}l_{oIOS}) + \\ - m_{opr}(t_p)k_{o2p}c_{jop} - m_{orIOS}(t_p)k_{o2IOS}c_{joIOS} \quad (4.62)$$

gdzie:

$$m_{opr}(t_p) = w_{op}B_p(t_p)p = w_{op}p \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} 10^3 \quad (4.63)$$

$m_{opr}(t_p)$ – ilość odpadów paleniskowych powstałych w trakcie rozruchu po czasie postoju t_p , Mg; $m_{orIOS}(t_p)$ – ilość odpadów z IOS powstałych w trakcie rozruchu po czasie postoju t_p , określana na podstawie szacunkowych obliczeń, Mg; pozostałe oznaczenia jak we wzorach (4.32) i (4.36).

Koszty odprowadzania ścieków powstałych podczas rozruchu proponuje się wyznaczać w uproszczony sposób wg wzoru:

$$K_{sr}(t_p) = M_{sr}(t_p) \left[(1 - k_{sr})w_{zs}s_{jz} + k_{sr}w_{zjcs}s_{jjcs} + w_{zmc}s_{jmc} + w_{zfl}s_{jfl} \right] \cdot 10^{-3} \quad (4.64)$$

gdzie: $M_{sr}(t_p)$ – szacunkowa ilość ścieków powstała w trakcie rozruchu po czasie postoju t_p , m³; k_{sr} – współczynnik określający jaką część ścieków powstałych podczas rozruchu stanowią zasolone ścieki z IOS ($0 \leq k_{sr} \leq 1$); pozostałe oznaczenia jak we wzorze (4.37).

Każde wyłączenie bloku z ruchu, a następnie załączenie go do ruchu i podniesienie parametrów pary oraz obciążenie do wartości nominalnych, stanowi potencjalne niebezpieczeństwo uszkodzenia jego części wskutek powstania w elementach grubościennych, ciśnieniowych dużych różnic temperatur oraz dużych naprężeń cieplnych i mechanicznych. Cykliczne zmiany temperatury przy rozruchu i odstawieniu bloku mają ponadto charakter zmęczeniowy dla metalu i przyspieszają jego zużycie. Koszty remontów, napraw, konserwacji i przeglądów wskutek częstych odstawień i uruchomień szacuje się ze wzoru [Jan92], [Jan68]:

$$K_{ur} = k_{ur}P_N \quad (4.65)$$

gdzie: k_{ur} – wskaźnik wzrostu kosztów remontów i utrzymania przypadających na jedno odstawienie, zł/MW; P_N – moc nominalna bloku, MW.

Wyłączanie bloków do rezerwy powoduje zmniejszenie dyspozycyjności bloków i skrócenie ich żywotności, a co za tym idzie (oprócz wzrostu kosztów remontów) [Gła99]:

- wzrost kosztów produkcji energii elektrycznej w SEE, w wyniku przejmowania obciążenia przez mniej sprawne bloki,
- pogorszenie niezawodności wytwarzania, co może spowodować wzrost strat u odbiorców,
- konieczność wzrostu planowej rezerwy mocy w SEE z powodu wzrostu planowych remontów, co pociąga za sobą wzrost kosztów instalowania nowych mocy,
- konieczność wzrostu awaryjnej rezerwy mocy, co również pociąga instalowanie nowych mocy.

Oszacowanie kosztów usuwania ujemnych skutków pracy przerywanej i kosztów znacznego zaniżenia mocy bloku wymaga specjalistycznych badań. Na podstawie istniejących przesłanek można przyjąć, że suma wydatków na działalność konserwatorsko – remontową w elektrowniach pracujących szczytowo jest ok. dwukrotnie wyższa niż przy pracy podstawowej.

Według innych źródeł [Gła99] koszty związane z pracą przerywaną urządzeń wytwórczych uwzględnia się poprzez wprowadzenie współczynnika k_s , przez który przemnaża się koszty paliwa i wody. Na podstawie dotychczas przeprowadzonych oszacowań, wartość k_s zmienia się w granicach od 1,5 do 2.

Charakterystyka kosztów rozruchu JW, z uwzględnieniem współczynnika remontowego k_s i powyżej prezentowanych zależności, przyjmuje postać:

$$\begin{aligned}
K_r(t_p) = & k_s \left[\frac{Q_r(t_p) - Q_{rr}(t_p)}{W} (c_{jzp} + c_{jip}) \cdot 10^3 + \frac{Q_{rr}(t_p)}{W_r} (c_{jzr} + c_{jir}) \cdot 10^3 + z_{wdr}(t_p) c_{jw} \right] + \\
& + \left[w_{zs} s \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + w_{zsr} s_r \frac{Q_{rr}(t_p)}{W_r} \right] c_{js} \cdot 10^3 + z_{wrIOS}(t_p) c_{jw} + A_{rIOS}(t_p) c_{jMWh} + \\
& + z_{rNH_3}(t_p) c_{jNH_3} + w_{zkat} p \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} c_{jkat} \cdot 10^3 + A_{rNO_x}(t_p) c_{jMWh} + \\
& + \left[w_{up} p \frac{Q_r(t_p) - Q_{rr}(t_p)}{W(100 - c_p)} 10^2 + w_{urp} \frac{Q_{rr}(t_p)}{W_r \rho_r} \right] (100 - \eta_{odp}) s_{jp} \cdot 10^1 + \left[w_{uSO_2} s \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + \right. \\
& + w_{urSO_2} s_r \frac{Q_{rr}(t_p)}{W_r \rho_r} \left. \right] (100 - \eta_{IOS}) s_{jSO_2} \cdot 10^1 + \left[w_{uNO_x} \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + w_{urNO_x} \frac{Q_{rr}(t_p)}{W_r \rho_r} \right] \\
& (100 - \eta_{NO_x}) s_{jNO_x} \cdot 10^1 + \left[w_{uCO_2} \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + w_{urCO_2} \frac{Q_{rr}(t_p)}{W_r \rho_r} \right] s_{jCO_2} \cdot 10^3 + \\
& + \left[w_{uCO} \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} + w_{urCO} \frac{Q_{rr}(t_p)}{W_r \rho_r} \right] s_{jCO} \cdot 10^3 + w_{op} p \frac{Q_r(t_p) - Q_{rr}(t_p)}{W} \left[k_{o1p} s_{jop} \right. \\
& (1 + r_{so} l_{op}) 10^3 - k_{o2p} c_{jop} \left. \right] + m_{orIOS}(t_p) \left[k_{o1IOS} s_{joIOS} (1 + r_{so} l_{oIOS}) - k_{o2IOS} c_{joIOS} \right] + \\
& + M_{sr}(t_p) \left[(1 - k_{sr}) w_{zs} s_{jz} + k_{sr} w_{zjes} s_{jjes} + w_{zmc} s_{jmc} + w_{zfl} s_{jfl} \right] \cdot 10^{-3} \quad (4.66)
\end{aligned}$$

W powyższym wzorze należy podstawić: $w_{zs} = 0$, $z_{wrIOS} = 0$, $A_{rIOS} = 0$, $\eta_{IOS} = 0$, $m_{orIOS} = 0$, $k_{sr} = 0$, jeśli blok nie posiada IOS lub instalacja ta nie funkcjonuje podczas rozruchu oraz: $z_{rNH_3} = 0$, $w_{zkat} = 0$, $A_{rNO_x} = 0$, $\eta_{NO_x} = 0$, jeśli blok nie posiada instalacji odazotowywania spalin lub instalacja ta nie funkcjonuje podczas rozruchu.

Charakterystyki kosztów rozruchów określono ze wzoru (4.66) dla każdego modelowanego bloku energetycznego z uwagami zamieszczonymi w dodatku 4. Wszystkie niezbędne dane potrzebne do sporządzenia tych charakterystyk zestawiono w dodatku 3. Skonstruowane na ich podstawie charakterystyki kosztów rozruchów bloków energetycznych w formie tabelarycznej zamieszczono w dodatku 5 (tab. D5.13 – D5.24).

Do aproksymacji charakterystyk kosztów rozruchu użyto funkcji wykładniczych:

$$K_r(t_p) = w_e [1 - \exp(-w_g t_p)] + w_f \quad (4.67)$$

$$K_r(t_p) = w_e t_p^{-w_g} + w_f \quad (4.68)$$

$$K_r(t_p) = w_e \exp(-w_g t_p) + w_f \exp(-w_h t_p) \quad (4.69)$$

gdzie: w_e , w_f , w_g , w_h – parametry.

Miarą oceny aproksymacji był błąd:

$$\delta_k = \frac{|K_{rk} - \widehat{K}_{rk}|}{K_{rk}} 100\% \quad (4.70)$$


gdzie: k – indeks punktu charakterystyki tabelarycznej, $k = 1, 2, 3, 4$; K_{rk} – koszty rozruchu z charakterystyki tabelarycznej, zł; \widehat{K}_{rk} – koszty rozruchu aproksymowane w punkcie k , zł.

Aproksymacja funkcją (4.67) wykazywała błąd średni $\bar{\delta} = 7,02\%$, natomiast funkcją (4.68) – $\bar{\delta} = 2,44\%$. Najlepsze przybliżenie charakterystyki tabelarycznej uzyskano wykorzystując funkcję (4.69) – $\bar{\delta} = 8,95 \cdot 10^{-7}\%$. Błędy aproksymacji oraz parametry funkcji aproksymującej dla tego przypadku zamieszczono w tabelicy 4.4. Aproksymowane charakterystyki kosztów rozruchów pokazano na rys. 4.7.

Niewielkie zróżnicowanie charakterystyk wynika z braku dokładnych, określonych dla każdej jednostki charakterystyk strat rozruchowych, na bazie których wyznacza się charakterystyki kosztów rozruchu. Dysponowano jedynie uśrednioną dla wszystkich bloków charakterystyką strat rozruchowych otrzymaną z KDM.

Tablica 4.4. Parametry funkcji aproksymujących (4.69) charakterystyki kosztów rozruchów oraz błędy aproksymacji w %. Źródło: opracowanie własne.

Blok nr	Współczynniki funkcji (4.69)				Błędy aproksymacji
	w_e	w_f	w_g	w_h	
1	-11557,81	21865,13	0,3680237	-0,0111735	$1,16 \cdot 10^{-6}$
2	-11575,23	21898,05	0,3680230	-0,0111735	$1,39 \cdot 10^{-6}$
3	-11555,38	21860,54	0,3680222	-0,0111735	$8,41 \cdot 10^{-7}$
4	-11531,09	21814,64	0,3680226	-0,0111735	$1,18 \cdot 10^{-6}$
5	-11455,77	21672,28	0,3680207	-0,0111735	$6,00 \cdot 10^{-6}$
6	-11372,52	21514,96	0,3680193	-0,0111734	$5,68 \cdot 10^{-7}$
7	-11504,62	21764,61	0,3680213	-0,0111735	$7,00 \cdot 10^{-7}$
8	-11613,16	21968,88	0,3680287	-0,0111736	$1,19 \cdot 10^{-6}$
9	-11570,92	21889,90	0,3680220	-0,0111735	$8,73 \cdot 10^{-7}$
10	-11714,59	22160,58	0,3680319	-0,0111737	$6,95 \cdot 10^{-7}$
11	-11579,50	21905,29	0,3680294	-0,0111736	$1,06 \cdot 10^{-6}$
12	-11662,10	22061,38	0,3680318	-0,0111736	$4,77 \cdot 10^{-7}$



Rys. 4.7. Charakterystyki kosztów rozruchu modelowanych bloków energetycznych. Źródło: opracowanie własne.

4.4. MODELE OPTIMALIZACYJNE DO EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ – PODEJŚCIE KOMBINOWANE

W podejściu kombinowanym stosuje się algorytmy ewolucyjne (podrozdział 4.4.1), algorytmy symulowanego wyżarzania (podrozdział 4.4.2) oraz algorytm będący hybrydą symulowanego wyżarzania i algorytmu ewolucyjnego (podrozdział 4.4.3). Rozważa się dwa sposoby definicji zmiennych i dostosowane do nich metody reprezentacji:

- zmiennymi są wartości funkcji binarnych $\alpha_i(t)$ reprezentowane w kodzie binarnym,
- zmiennymi są czasy załączeń i odstawiń jednostek reprezentowane w kodzie binarnym lub całkowitoliczbowym.

W AE wprowadza się łącznie sześć metod mutacji:

- mutację binarną równomierną MBR,
- mutację binarną zależną od liczby jednostek niezbędnych do pokrycia zapotrzebowania MB1,
- mutację binarną „przesunięć momentów rozruchów i odstawiń” MB2,
- mutację binarną zależną od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MB3,
- mutację całkowitoliczbową równomierną MCR,
- mutację całkowitoliczbową nierównomierną MCN

oraz sześć metod rekombinacji:

- krzyżowanie jednopunktowe K1P,
- krzyżowanie wielopunktowe KWP,
- krzyżowanie jednorodne w wersji binarnej KJR i całkowitoliczbowej KCJ,
- krzyżowanie arytmetyczne w wersji całkowitoliczbowej KCA,
- krzyżowanie heurystyczne w wersji całkowitoliczbowej KCH.

Ponadto wprowadza się operator transpozycji OT, przeszukujący minima lokalne funkcji kosztu. Do selekcji używa się metody turniejowej.

Metody przesunięcia (*move, transition*) w SW pokrywają się z metodami mutacji i transpozycji. Zastosowano dwa schematy wyżarzania: klasyczny Kirkpatricka [Kir83] oraz adaptacyjny Aartsa i van Laarhovena [Aar89].

Zaproponowano algorytm hybrydowy SW+AE z wyżarzaniem wg schematu Kirkpatricka, operatorami przesunięcia jak w SW oraz z czterema strategiami postępowania z punktami zwróconymi przez równoległe procesy wyżarzania:

- rekombinacją losową SRL,
- rekombinacją wg kryterium odległościowego SRO,
- rekombinacją z najlepszym punktem SRN,
- mikrowyżarzaniem SMW.

Ograniczenia funkcji kosztu, we wszystkich algorytmach optymalizacyjnych ERO-k, eliminuje się stosując strategię naprawy rozwiązań niedopuszczalnych (losową lub deterministyczną) oraz strategię z funkcją kary.

W podrozdziale 4.4.4 przedstawiono wyniki przykładowych obliczeń optymalizacyjnych ekonomicznego rozdziału obciążeń z podejściem kombinowanym.

4.4.1. ALGORYTMY EWOLUCYJNE

4.4.1.1. ALGORYTM Z BINARNĄ REPREZENTACJĄ STANÓW PRACY JEDNOSTEK

4.4.1.1.1. REPREZENTACJA ZMIENNYCH RB1

W podejściu tym zmiennymi są wartości funkcji binarnych $\alpha_i(t)$ dla $i = 1, 2, \dots, N$ oraz $t = 1, 2, \dots, T$. Zadanie sprowadza się do wyznaczenia stanów jednostek („załączona” lub „odstawiona”) w okresie T , przy których osiąga się minimum funkcji kosztu (4.2), wybranych z pewnego zbioru możliwych kombinacji stanów.

Chromosom składa się z genów binarnych przyjmujących wartości zmiennych $\alpha_i(t)$ dla kolejnych JW i kolejnych chwil okresu optymalizacji. Sposób kodowania przedstawiono w tablicy 4.5.

Tablica 4.5. Sposób kodowania w algorytmie z binarną reprezentacją stanów pracy jednostek. Źródło: opracowanie własne.

Postać chromosomu:	b_1	b_2	...	b_N	b_{N+1}	b_{N+2}	...	b_{2N}	...	$b_{(T-1)N+1}$	$b_{(T-1)N+2}$...	b_{TN}
Przykładowy chromosom:	1	1	...	0	0	1	...	0	...	1	1	...	0
Znaczenie genów:	$\alpha_1(1)$	$\alpha_2(1)$...	$\alpha_N(1)$	$\alpha_1(2)$	$\alpha_2(2)$...	$\alpha_N(2)$...	$\alpha_1(T)$	$\alpha_2(T)$...	$\alpha_N(T)$

gdzie: b_j – wartość binarna.

Dla liczby jednostek $N = 12$ i horyzontu optymalizacji $T = 24$ h chromosom posiada 288 bitów.

4.4.1.1.2. OPERATORY EWOLUCYJNE I GENETYCZNE

Selekcja

Do eksperymentów wybrano metodę selekcji turniejowej z rozmiarem turnieju $r_t = 2$ (turniej binarny), którą stosuje się dla wszystkich sposobów reprezentacji zmiennych. W generacji o indeksie l_{gen} selekcja turniejowa operuje na populacji \mathcal{P}_{gen} złożonej z L_{pop} osobników. W wyniku selekcji tworzona jest pula rodzicielska, która podlega rekombinacji, transpozycji i mutacji, co prowadzi do utworzenia populacji potomnej. Stosuje się też

strategię elitarną, która kopiuje najlepszego osobnika rodzicielskiego w populacji \mathcal{P}_{gen} do populacji $\mathcal{P}_{(gen+1)}$. W programie komputerowym zamieszczonym w dodatku 8, selekcję turniejową zaimplementowano w funkcji TURNIEJ.m.


Metody rekombinacji

Dla binarnej reprezentacji stanów pracy jednostek zastosowano trzy standardowe metody krzyżowania [Bac97, rozdz. C3.3]: jednopunktowe K1P, wielopunktowe KWP i jednorodnie KJR. Krzyżowanie zachodzi z prawdopodobieństwem¹ $p_k \in \langle 0, 1 \rangle$. W przypadku krzyżowania jednopunktowego i wielopunktowego miejsca cięcia chromosomów ustala się losowo². W krzyżowaniu jednorodnym (równomiernym, jednolitym) potomkowie dziedziczą geny rodziców zgodnie z wylosowanym wzorcem binarnym. Pierwszy potomek dziedziczy te geny pierwszego rodzica, które odpowiadają wartościom 1 we wzorcu, pozostałe geny pochodzą od drugiego rodzica. Drugi potomek odwrotnie. Wprowadzając współczynnik jednorodności $w_j = 0 \div 0,5$ można sterować liczbą genów przejętych od rodziców i tym samym stopniem podobieństwa potomków do rodziców.

Operatory krzyżowania zrealizowano w funkcjach KRZYZ_1P.m, KRZYZ_WP.m i KRZYZ_JR.m.

Transpozycja

Wprowadza się operację transpozycji, która zamienia ze sobą fragmenty chromosomu kodujące stany (harmonogramy pracy) dwóch wybranych losowo jednostek wytwórczych. Intensywność działania tego operatora określa oczekiwana liczba transpozycji chromosomu $w_t \in R_+$. Chromosomy do transpozycji wybiera się z populacji losowo. Jeśli jednostki scharakteryzowane są różnymi minimalnymi czasami postoju w rezerwie t_{pmin} , różnymi czasami pracy po załączeniu t_{rmin} i różnymi zakresami generacji, transpozycja może produkować rozwiązania niedopuszczalne. Operator ten zilustrowano na rysunku 4.8.



Rys. 4.8. Działanie operatora transpozycji na wybranym do transpozycji chromosomie ch .
Źródło: opracowanie własne.

¹ Prawdopodobieństwo krzyżowania zależy od ustawień i parametrów algorytmu (rozmiaru populacji, prawdopodobieństwa mutacji, metody selekcji), można je też modyfikować adaptacyjnie [Bac97, rozdz. C3.3]. Często ustala się je arbitralnie.

² Jeśli w rozprawie mowa o losowym ustalaniu lub wyborze operacja ta zachodzi z rozkładem jednostajnym.

Wydaje się, że transpozycja może istotnie wspomagać proces ewolucyjny, szczególnie w końcowej fazie, penetrując minima lokalne poprzez zamianę harmonogramów pracy pary jednostek.

Transpozycję realizuje funkcja TRANSPOZYCJA.m.

Mutacja binarna równomierna MBR

Mutacja binarna równomierna polega na zmianie wartości bitu na przeciwną. Bity podlegające mutacji losowane są z populacji osobników z równym prawdopodobieństwem, niezależnym od locus oraz numeru generacji. Standardowo intensywność mutacji określa prawdopodobieństwo mutacji bitu p_m . Zamiast prawdopodobieństwa mutacji wprowadza się bardziej informatywny parametr nazwany wskaźnikiem mutacji $w_m \in R_+$, tożsamy z oczekiwaną liczbą mutacji chromosomu. Prawdopodobieństwo mutacji bitu można wyznaczyć ze wskaźnika mutacji wg wzoru:

$$p_m = \frac{w_m}{m} \quad (4.71)$$

gdzie: m – liczba genów w chromosomie.

Wskaźnik mutacji określa intensywność mutacji we wszystkich prezentowanych w pracy metodach mutacji.

Mutacja binarna równomierna została zaimplementowana w funkcji MUTACJA_BR.m.

Mutacja binarna zależna od liczby jednostek niezbędnych do pokrycia zapotrzebowania MB1

Intuicyjnie prawdopodobieństwo zmiany bitu z 0 na 1 (załączenia JW) lub z 1 na 0 (wyłączenia JW) zależne jest od liczby jednostek potrzebnych do pokrycia zadanego w chwili t zapotrzebowania. Przy wysokim zapotrzebowaniu, bliskim mocy osiągalnej elektrowni, wszystkie lub prawie wszystkie dyspozycyjne JW znajdują się w ruchu (w rozpatrywanym zadaniu moc szczytowa P_{zmax} i rezerwa wirująca P_{rw} może być pokryta przez 11 lub 12 JW). Mechanizm opisanej powyżej mutacji równomiernej zamienia wtedy niepotrzebnie wybrane do mutacji jedynki (oznaczające załączenie JW) na zera, co spowalnia zbieżność¹ AE. Aby temu zapobiec wprowadza się metodę mutacji MB1 polegającą na ustawieniu losowo wybranego do mutacji bitu na 1, z pewnym prawdopodobieństwem $p_{w1}(t)$, które określa się dla każdej dyskretnej chwili okresu optymalizacji T . Prawdopodobieństwo to zależy od średniej liczby jednostek niezbędnych do pokrycia zapotrzebowania w chwili t wg wzoru:

$$p_{w1}(t) = \frac{l_{jmin}(t) + l_{jmax}(t)}{2N} \quad (4.72)$$

w którym $l_{jmin}(t)$, $l_{jmax}(t)$ – minimalna i maksymalna liczba JW niezbędnych do pokrycia zapotrzebowania w chwili t .

¹ Przez zbieżność rozumie się ciąg najlepszych przystosowań osobników w kolejnych populacjach [Sch01, p.8].

Jeśli przez L_1 oznaczymy listę JW posortowaną malejąco względem mocy osiągalnych $P_{n\max}$, to minimalną liczbę JW do pokrycia zapotrzebowania otrzymujemy sumując moce osiągalne kolejnych JW z listy L_1 do momentu, gdy suma ta przekracza zapotrzebowanie i rezerwę wirującą:

$$l_{j\min}(t) = \min_{\substack{L_1(l_j) \\ \sum_{i=L_1(1)} P_{n\max i} \geq P_z(t) + P_{rw}(t)}} \{l_j\} \quad (4.73)$$

przy czym: l_j – zmienna pomocnicza oznaczająca liczbę JW, $l_j, l_{j\min} \in \{1, 2, \dots, N\}$; L_1 – lista JW posortowana malejąco względem mocy osiągalnych $P_{n\max}$.

Maksymalną liczbę JW potrzebną do pokrycia zapotrzebowania otrzymujemy następująco. Wprowadzamy listę L_2 jednostek posortowaną rosnąco względem minimów technicznych $P_{n\min}$. Sumujemy minima techniczne kolejnych JW z listy L_2 znajdując największą liczbę jednostek l_j , przy której suma ta nie przekroczy zapotrzebowania:

$$l_{j\max}(t) = \max_{\substack{L_2(l_j) \\ \sum_{i=L_2(1)} P_{n\min i} \leq P_z(t)}} \{l_j\} \quad (4.74)$$

przy czym: $l_{j\max} \in \{1, 2, \dots, N\}$; L_2 – lista JW posortowana rosnąco względem minimów technicznych $P_{n\min}$.

Minimalną i maksymalną liczbę jednostek potrzebnych do pokrycia zapotrzebowania zwraca funkcja LJ_MINMAX.m.

Dla wybranego do mutacji bitu wyznacza się $p_{w1}(t)$, a następnie ustala się jego wartość losując ją ze zbioru $\{0, 1\}$ z prawdopodobieństwem $\{1 - p_{w1}(t), p_{w1}(t)\}$.

W rozwiązywanym zadaniu, dla najmniejszej wartości zapotrzebowania $P_z(4) = 1800$ MW, przy poziomie rezerwy $P_{rw}(4) = 175$ MW, minimalna i maksymalna liczba jednostek wymaganych do pokrycia zapotrzebowania wynosi: $l_{j\min}(4) = 6$, $l_{j\max}(4) = 10$, stąd $p_{w1}(4) = 0,6667$. Dla zapotrzebowania szczytowego $P_z(18) = 3500$ MW otrzymujemy: $l_{j\min}(18) = 11$, $l_{j\max}(18) = 12$, $p_{w1}(18) = 0,9583$.


Mutację MB1 zaprogramowano w funkcji MUTACJA_B1.m.

Mutacja binarna „przesunięć momentów rozruchów i odstawiń” MB2


W metodzie tej – będącej adaptacją operatora przesunięcia w algorytmie SW, zaczerpniętego z publikacji [Man98] – z populacji losuje się chromosom podlegający mutacji nr_{ch} , numer jednostki nr_j oraz godzinę nr_h . Z chromosomu nr_{ch} pobiera się fragment ch_x kodujący stan jednostki nr_j w kolejnych godzinach okresu T . Wartość bitu $b(nr_h)$, kodującego stan jednostki nr_j o godzinie nr_h w sekwencji ch_x , zmienia się na przeciwną. Zmianie podlegają też wartości bitów sąsiednich we fragmencie ch_x (w kierunku na prawo lub na lewo od bitu $b(nr_h)$), pod warunkiem, że są one takie same jak bitu $b(nr_h)$. Jeśli zostanie napotkany

bit o wartości przeciwnej, dalsze bity nie są zmieniane. Kierunek modyfikacji jest losowany. Mutację MB2 zobrazowano na rys. 4.9.

Fragment ch_x przed mutacją:



Fragment ch_x po mutacji:



Rys. 4.9. Działanie operatora mutacji MB2 na fragmencie ch_x chromosomu. Źródło: opracowanie własne.

Mutacja MB2 przebiega wg następującego algorytmu (zaimplementowanego w funkcji MUTACJA_B2.m):

1. Wylosuj¹ numer chromosomu do mutacji $nr_{ch} \in \{1, 2, \dots, L_{pop}\}$, numer jednostki $nr_j \in \{1, 2, \dots, N\}$ oraz godzinę $nr_h \in \{1, 2, \dots, T\}$.
2. Pobierz z chromosomu o numerze nr_{ch} fragment ch_x odpowiadający wylosowanej JW. Stan jednostki nr_j o godzinie nr_h koduje w sekwencji ch_x bit $b(nr_h)$.
3. Wylosuj¹ wartość zmiennej binarnej r_b reprezentującej kierunek modyfikacji i wykonaj jedną z poniższych pętli warunkowych (p. 4 ÷ 7).
4. Jeśli $r_b = 0$ i $b(nr_h) = 0$ i $nr_h > 0$ powtarzaj:
 - 4.1. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 1: $b(nr_h) = 1$.
 - 4.2. Dekrementuj nr_h .
5. Jeśli $r_b = 1$ i $b(nr_h) = 0$ i $nr_h \leq T$ powtarzaj:
 - 5.1. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 1: $b(nr_h) = 1$.
 - 5.2. Inkrementuj nr_h .
6. Jeśli $r_b = 0$ i $b(nr_h) = 1$ i $nr_h > 0$ powtarzaj:
 - 6.1. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 0: $b(nr_h) = 0$.
 - 6.2. Dekrementuj nr_h .
7. Jeśli $r_b = 1$ i $b(nr_h) = 1$ i $nr_h \leq T$ powtarzaj:
 - 7.1. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 0: $b(nr_h) = 0$.
 - 7.2. Inkrementuj nr_h .
8. Włącz do chromosomu o numerze nr_{ch} zmodyfikowany fragment ch_x .

Metoda mutacji MB2 zmienia we fragmencie ch_x ciąg sąsiadujących bitów o jednakowej wartości, co oznacza przesunięcie czasu odstawienia lub załączenia jednostki. Zmiana stanu jednostki następuje tu dla ciągu kolejnych chwil t , nie tak, jak w metodach MBR i MB1 dla chwil pojedynczych, bez uwzględnienia stanu JW w chwilach sąsiednich. Mechanizm ten

¹ Patrz przypis ² na str. 81.

pozwała uniknąć przypadków wielokrotnego odstawiania i załączania JW w ciągu okresu T i przyspiesza zbieżność AE.

Mutacja binarna zależna od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MB3

W tej metodzie uzależnia się prawdopodobieństwo mutacji od wymaganej do pokrycia zapotrzebowania liczby jednostek, kosztów zmiennych pracy jednostek oraz kosztów ich rozruchów. Prawdopodobieństwo zmiany wybranego do mutacji bitu z 0 na 1, oznaczające załączenie jednostki w chwili t , jest równe ilorazowi średniej liczby jednostek potrzebnych do pokrycia zapotrzebowania $P_z(t)$ i liczby jednostek dyspozycyjnych N wg wzoru (4.72). Zakres zmian wartości tego prawdopodobieństwa można ograniczyć wprowadzając dodatkowy parametr a_{zj1} :

$$p_{zj1}(t) = a_{zj1} + (1 - a_{zj1}) \frac{l_{j\min}(t) + l_{j\max}(t)}{2N} \quad 1 \leq t \leq T \quad (4.75)$$

gdzie: $p_{zj1}(t)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 0 na 1, zależne od liczby jednostek potrzebnych do pokrycia zapotrzebowania w chwili t , $a_{zj1} \leq p_{zj1} \leq 1$; $l_{j\min}(t)$, $l_{j\max}(t)$ – minimalna i maksymalna liczba jednostek potrzebnych do pokrycia zapotrzebowania w chwili t , określana ze wzorów (4.73) i (4.74).

Prawdopodobieństwo p_{zj1} przyjmuje wartość maksymalną (równą 1) dla zapotrzebowania zbliżonego do mocy osiągalnej elektrowni. Dolna wartość tego prawdopodobieństwa występuje przy minimalnym zapotrzebowaniu dobowym i jest nie mniejsza od a_{zj1} .

Prawdopodobieństwo zmiany bitu, reprezentującego stan jednostki i -tej, z 0 na 1 uzależnia się od jej kosztów zmiennych następująco:

$$p_{zj2}(i) = a_{zj2} + (1 - a_{zj2}) \frac{S_{Kzi} - S_{Kz\min}}{S_{Kz\max} - S_{Kz\min}} \quad 1 \leq i \leq N \quad (4.76)$$

przy czym:

$$S_{Kzi} = \frac{\min_{j=1,2,\dots,N} \{K_{zj}(P_{n\max j}) / P_{n\max j}\}}{K_{zi}(P_{n\max i}) / P_{n\max i}} \quad (4.77)$$

$$S_{Kz\min} = \min_{i=1,2,\dots,N} \{S_{Kzi}\} \quad (4.78)$$

$$S_{Kz\max} = \max_{i=1,2,\dots,N} \{S_{Kzi}\} \quad (4.79)$$

gdzie: $p_{zj2}(i)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 0 na 1, zależne od jednostkowych kosztów zmiennych pracy jednostki i -tej, $a_{zj2} \leq p_{zj2} \leq 1$; s_{Kzi} – stosunek jednostkowego kosztu zmiennego przy obciążeniu osiągalnym najbardziej ekonomicznej

jednostki do jednostki i -tej; s_{Kzmin} , s_{Kzmax} – minimalna i maksymalna wartość zmiennej s_{Kzi} dla $i = 1, 2, \dots, N$.

Prawdopodobieństwo p_{zj2} przyjmuje wartość minimalną, równą a_{zj2} , dla JW o największym jednostkowym koszcie zmiennym, a wartość maksymalną, równą 1, dla jednostki o najmniejszym koszcie jednostkowym.

Łączne prawdopodobieństwo zmiany wybranego do mutacji bitu, reprezentującego stan jednostki i -tej w chwili t , z 0 na 1 proponuje się wyznaczać ze wzoru:

$$p_{zj}(i, t) = \begin{cases} 1, & \text{jeśli } p_{zj1}(t) + p_{zj2}(i) - \frac{1 + a_{zj2}}{2} > 1 \\ 0, & \text{jeśli } p_{zj1}(t) + p_{zj2}(i) - \frac{1 + a_{zj2}}{2} < 0 \\ p_{zj1}(t) + p_{zj2}(i) - \frac{1 + a_{zj2}}{2} & \text{w innych przypadkach} \end{cases} \quad (4.80)$$

gdzie: $p_{zj}(i, t)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 0 na 1, bit ten reprezentuje stan jednostki i -tej w chwili t , $\max\left(0, a_{zj1} - \frac{1 - a_{zj2}}{2}\right) \leq p_{zj} \leq 1$.

Analogicznie prawdopodobieństwo zmiany bitu z 1 na 0, oznaczające odstawienie jednostki do rezerwy, uzależnia się od liczby jednostek niezbędnych do pokrycia zapotrzebowania $P_z(t)$ wg wzoru:

$$p_{oj1}(t) = 1 - (1 - a_{oj1}) \frac{l_{jmin}(t) + l_{jmax}(t)}{2N} \quad 1 \leq t \leq T \quad (4.81)$$

gdzie: $p_{oj1}(t)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 1 na 0, zależne od liczby jednostek potrzebnych do pokrycia zapotrzebowania w chwili t , $a_{oj1} \leq p_{oj1} \leq 1$; a_{oj1} – dolna wartość graniczna p_{oj1} .

Minimalna wartość prawdopodobieństwa p_{oj1} , równa a_{oj1} , występuje dla zapotrzebowania zbliżonego do mocy osiągalnej elektrowni, a wartość maksymalna – przy minimalnym zapotrzebowaniu dobowym.

Zależność prawdopodobieństwa zmiany mutowanego bitu z 1 na 0 od kosztu rozruchu jednostki i -tej definiuje wzór:

$$p_{oj2}(i) = a_{oj2} + (1 - a_{oj2}) \frac{s_{Kri} - s_{Krmin}}{s_{Krmax} - s_{Krmin}} \quad 1 \leq i \leq N \quad (4.82)$$

przy czym:

$$s_{Kri} = \frac{\min_{j=1,2,\dots,N} \{K_{rj}(t_{px})\}}{K_{ri}(t_{px})} \quad (4.83)$$

$$s_{Kmin} = \min_{i=1,2,\dots,N} \{s_{Kri}\} \quad (4.84)$$

$$s_{Kmax} = \max_{i=1,2,\dots,N} \{s_{Kri}\} \quad (4.85)$$

gdzie: $p_{oj2}(i)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 1 na 0, zależne od kosztów rozruchu jednostki i -tej, $a_{oj2} \leq p_{oj2} \leq 1$; s_{Kri} – stosunek kosztów rozruchu po czasie postoju t_{px} jednostki o najmniejszym koszcie rozruchu do kosztów rozruchu jednostki i -tej; s_{Kmin} , s_{Kmax} – minimalna i maksymalna wartość zmiennej s_{Kri} dla $i = 1, 2, \dots, N$.

Prawdopodobieństwo p_{oj2} przyjmuje wartość minimalną, równą a_{oj2} , dla JW największym koszcie rozruchu po czasie postoju t_{px} , a wartość maksymalną, równą 1, dla jednostki o najniższym koszcie rozruchu.

Prawdopodobieństwo zmiany bitu z 1 na 0 w zależności od kosztów zmiennych jednostki i -tej określa się ze wzoru:

$$p_{oj3}(i) = 1 - (1 - a_{oj3}) \frac{s_{Kzi} - s_{Kzmin}}{s_{Kzmax} - s_{Kzmin}} \quad 1 \leq i \leq N \quad (4.86)$$

gdzie: $p_{oj3}(i)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 1 na 0, zależne od kosztów zmiennych jednostki i -tej, $a_{oj3} \leq p_{oj3} \leq 1$; s_{Kzi} , s_{Kzmin} , s_{Kzmax} – liczone ze wzorów (4.77) ÷ (4.79).

Dla JW o najmniejszym jednostkowym koszcie zmiennym prawdopodobieństwo p_{oj3} przyjmuje wartość minimalną równą a_{oj3} , natomiast dla jednostki o największym jednostkowym koszcie zmiennym – wartość maksymalną równą 1.


Łączne prawdopodobieństwo zmiany mutowanego bitu, reprezentującego stan jednostki i -tej w chwili t , z 1 na 0 określa się ze wzoru:

$$p_{oj}(i, t) = \begin{cases} 1, & \text{jeśli } p_{oj1}(t) + p_{oj2}(i) + p_{oj3}(i) - \frac{1 + a_{oj2}}{2} - \frac{1 + a_{oj3}}{2} > 1 \\ 0, & \text{jeśli } p_{oj1}(t) + p_{oj2}(i) + p_{oj3}(i) - \frac{1 + a_{oj2}}{2} - \frac{1 + a_{oj3}}{2} < 0 \\ p_{oj1}(t) + p_{oj2}(i) + p_{oj3}(i) - \frac{1 + a_{oj2}}{2} - \frac{1 + a_{oj3}}{2} & \text{w innych przypadkach} \end{cases} \quad (4.87)$$

gdzie: $p_{zo}(i, t)$ – prawdopodobieństwo zmiany wybranego do mutacji bitu z 1 na 0, bit ten reprezentuje stan jednostki i -tej w chwili t , $\max\left(0, a_{oj1} - \frac{1 - a_{oj2}}{2} - \frac{1 - a_{oj3}}{2}\right) \leq p_{oj} \leq 1$.

Wartości parametrów a_{zj1} , a_{zj2} , a_{oj1} , a_{oj2} i a_{oj3} dobiera się heurystycznie. Dla $a_{zj1} = 0$ i $a_{oj1} = 0$ prawdopodobieństwo p_{zj1} pokrywa się z prawdopodobieństwem p_{w1} określonym

wzorem (4.72), natomiast $p_{oj1} = (1 - p_{w1})$. W takim przypadku, dla przyjętego w zadaniu przebiegu zapotrzebowania i charakterystyk JW, rozważane prawdopodobieństwa zmieniają się w granicach: $0,6667 \leq p_{zj1} \leq 0,9583$ oraz $0,0417 \leq p_{oj1} \leq 0,3333$. Składniki $p_{zj2}(i) - \frac{1+a_{zj2}}{2}$, $p_{oj2}(i) - \frac{1+a_{oj2}}{2}$ oraz $p_{oj3}(i) - \frac{1+a_{oj3}}{2}$ we wzorach (4.80) i (4.87) mają sens poprawek do prawdopodobieństw zależnych od liczby jednostek potrzebnych do pokrycia zapotrzebowania p_{zj1} i p_{oj1} . Poprawki te zmieniają się w zakresach odpowiednio: $\left\langle -\frac{1+a_{zj2}}{2}, \frac{1+a_{zj2}}{2} \right\rangle$, $\left\langle -\frac{1+a_{oj2}}{2}, \frac{1+a_{oj2}}{2} \right\rangle$ oraz $\left\langle -\frac{1+a_{oj3}}{2}, \frac{1+a_{oj3}}{2} \right\rangle$. Na rys. 4.10 pokazano prawdopodobieństwa zmiany wylosowanego do mutacji bitu na 1 – $p_{zj}(i,t)$, w zależności od chwili $t = 1, 2, \dots, 24$, natomiast na rys. 4.11 – prawdopodobieństwa zmiany wylosowanego do mutacji bitu na 0 – $p_{oj}(i,t)$, przy: $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$. Takie wartości parametrów przyjęto w obliczeniach optymalizacyjnych (podrozdz. 4.4.4 i 4.5.3).




Rys. 4.10. Prawdopodobieństwa zmiany bitu z 0 na 1 (załączenia wybranej do mutacji jednostki; $i = 1, 2, \dots, 12$) $p_{zj}(i,t)$ w zależności od chwili $t = 1, 2, \dots, 24$, dla: $a_{zj1} = 0$, $a_{zj2} = 0,8$, zadanego przebiegu zapotrzebowania $P_z(t)$ oraz zadanych charakterystyk kosztów zmiennych jednostek $K_{zi}(P_{ni})$. Źródło: opracowanie własne.

Obliczanie prawdopodobieństw załączenia i odstawienia jednostek realizuje funkcja PMUT.m.

Jeśli wybrany do mutacji bit $b(nr_j, nr_h)$, reprezentujący stan jednostki nr_j w chwili nr_h , zmieni wartość z 0 na 1 (z 1 na 0) i bity reprezentujące stan jednostki nr_j w chwilach sąsiednich (nr_h-1) oraz (nr_h+1) mają taką samą wartość jak bit $b(nr_j, nr_h)$ przed mutacją, analizuje się prawdopodobieństwa załączenia (odstawienia) jednostki i -tej dla tych chwil. Jeśli $p_{zj}(nr_j, nr_h-1) > p_{zj}(nr_j, nr_h+1)$ (lub $p_{oj}(nr_j, nr_h-1) > p_{oj}(nr_j, nr_h+1)$ w przypadku odstawienia) zmienia się wartość bitu $b(nr_j, nr_h-1)$ i kolejnych $b(nr_j, nr_h-2)$, $b(nr_j, nr_h-3)$, ..., pod warunkiem, że są one takie same jak wartość bitu $b(nr_j, nr_h)$ przed mutacją. Napotkanie

bitu o wartości przeciwnej kończy ten proces. Jeśli $p_{zj}(nr_j, nr_{h-1}) < p_{zj}(nr_j, nr_{h+1})$ (lub $p_{oj}(nr_j, nr_{h-1}) < p_{oj}(nr_j, nr_{h+1})$) analogicznie zmienia się bity $b(nr_j, nr_{h+1})$, $b(nr_j, nr_{h+2})$ itd.



Rys. 4.11. Prawdopodobieństwa zmiany bitu z 1 na 0 (odstawienia wybranej do mutacji jednostki; $i = 1, 2, \dots, 12$) $p_{oj}(i, t)$ w zależności od chwili $t = 1, 2, \dots, 24$, dla: $a_{oj1} = 0$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$, zadanego przebiegu zapotrzebowania $P_z(t)$ i zadanych charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$ oraz kosztów rozruchów jednostek $K_{ri}(t_{pi})$. Źródło: oprac. własne.

Szczegółowy algorytm mutacji zależnej od liczby bloków potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek zamieszczono poniżej (implementacja w funkcji MUTACJA_B3.m):

1. Wylosuj¹ numer chromosomu do mutacji $nr_{ch} \in \{1, 2, \dots, L_{pop}\}$, numer jednostki $nr_j \in \{1, 2, \dots, N\}$ oraz godzinę $nr_h \in \{1, 2, \dots, T\}$.
2. Pobierz z chromosomu o numerze nr_{ch} fragment ch_x odpowiadający wylosowanej jednostce. Stan jednostki nr_j o godzinie nr_h koduje we fragmencie ch_x bit $b(nr_h)$.
3. Jeśli $b(nr_h) = 0$ oblicz prawdopodobieństwo $p_{zj}(nr_j, nr_h)$ zmiany bitu na 1 ze wzoru (4.80).
 - 3.1. Wylosuj¹ liczbę r_r z zakresu $\langle 0, 1 \rangle$. Jeśli $r_r < p_{zj}(nr_j, nr_h)$ wykonaj:
 - 3.1.1. Zmień wartość bitu $b(nr_h)$ na 1.
 - 3.1.2. Jeśli $b(nr_{h-1}) = 0$ i $(nr_{h-1}) > 0$ oblicz $p_{zj}(nr_j, nr_{h-1})$, w przeciwnym przypadku przyjmij $p_{zj}(nr_j, nr_{h-1}) = 0$.
 - 3.1.3. Jeśli $b(nr_{h+1}) = 0$ i $(nr_{h+1}) \leq T$ oblicz $p_{zj}(nr_j, nr_{h+1})$, w przeciwnym przypadku przyjmij $p_{zj}(nr_j, nr_{h+1}) = 0$.
 - 3.1.4. Jeśli $p_{zj}(nr_j, nr_{h-1}) \neq p_{zj}(nr_j, nr_{h+1}) \neq 0$ i $p_{zj}(nr_j, nr_{h-1}) \geq p_{zj}(nr_j, nr_{h+1})$ wykonaj:
 - 3.1.4.1. Jeśli $b(nr_{h-1}) = 0$ i $(nr_{h-1}) > 0$ powtarzaj:
 - 3.1.4.1.1. Dekrementuj nr_h .
 - 3.1.4.1.2. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 1: $b(nr_h) = 1$.

¹ Patrz przypis ² na str. 81.

- 3.1.5. Jeśli $p_{zj}(nr_j, nr_{h-1}) \neq p_{zj}(nr_j, nr_{h+1}) \neq 0$ i $p_{zj}(nr_j, nr_{h-1}) < p_{zj}(nr_j, nr_{h+1})$ wykonaj:
- 3.1.5.1. Jeśli $b(nr_{h+1}) = 0$ i $(nr_{h+1}) \leq T$ powtarzaj:
- 3.1.5.1.1. Inkrementuj nr_h .
- 3.1.5.1.2. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 1: $b(nr_h) = 1$.
4. Jeśli $b(nr_h) = 1$ oblicz prawdopodobieństwo $p_{oj}(nr_j, nr_h)$ zmiany bitu na 0 ze wzoru (4.87).
- 4.1. Wylosuj liczbę r_r z zakresu $(0, 1)$. Jeśli $r_r < p_{oj}(nr_j, nr_h)$ wykonaj:
- 4.1.1. Zmień wartość bitu $b(nr_h)$ na 0.
- 4.1.2. Jeśli $b(nr_{h-1}) = 1$ i $(nr_{h-1}) > 0$ oblicz $p_{oj}(nr_j, nr_{h-1})$, w przeciwnym przypadku przyjmij $p_{zj}(nr_j, nr_{h-1}) = 0$.
- 4.1.3. Jeśli $b(nr_{h+1}) = 1$ i $(nr_{h+1}) \leq T$ oblicz $p_{oj}(nr_j, nr_{h+1})$, w przeciwnym przypadku przyjmij $p_{zj}(nr_j, nr_{h+1}) = 0$.
- 4.1.4. Jeśli $p_{zj}(nr_j, nr_{h-1}) \neq p_{zj}(nr_j, nr_{h+1}) \neq 0$ i $p_{zj}(nr_j, nr_{h-1}) \geq p_{zj}(nr_j, nr_{h+1})$ wykonaj:
- 4.1.4.1. Jeśli $b(nr_{h-1}) = 1$ i $(nr_{h-1}) > 0$ powtarzaj:
- 4.1.4.1.1. Dekrementuj nr_h .
- 4.1.4.1.2. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 0: $b(nr_h) = 0$.
- 4.1.5. Jeśli $p_{zj}(nr_j, nr_{h-1}) \neq p_{zj}(nr_j, nr_{h+1}) \neq 0$ i $p_{zj}(nr_j, nr_{h-1}) < p_{zj}(nr_j, nr_{h+1})$ wykonaj:
- 4.1.5.1. Jeśli $b(nr_{h+1}) = 1$ i $(nr_{h+1}) \leq T$ powtarzaj:
- 4.1.5.1.1. Inkrementuj nr_h .
- 4.1.5.1.2. Zmień w sekwencji ch_x wartość bitu o numerze nr_h na 0: $b(nr_h) = 0$.
5. Włącz do chromosomu o numerze nr_{ch} zmodyfikowany fragment ch_x .

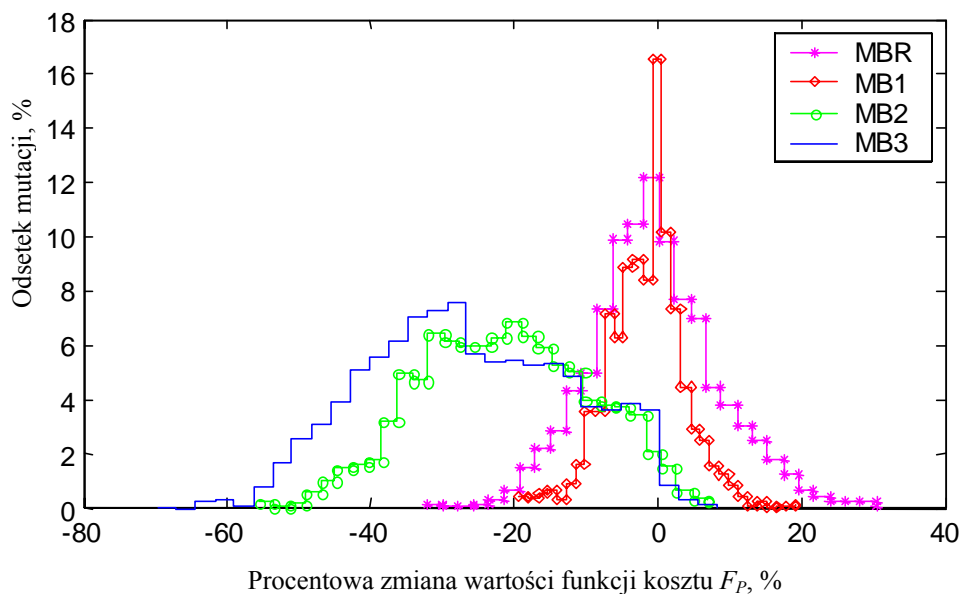
Podobnie jak mutacja „przesunięć momentów rozruchów i odstawień” MB2, proponowana metoda mutacji MB3 zmienia w sekwencji ch_x ciąg sąsiadujących bitów o jednakowej wartości, co oznacza przesunięcie czasu odstawienia lub załączenia jednostki, przy czym kierunek modyfikacji nie jest przypadkowy. Mechanizm ten zapobiega wielokrotnemu odstawianiu JW w ciągu doby.

Przedstawiona metoda mutacji MB3 pełni trzy funkcje:

1. Uzależnia częstość wyboru jednostek do załączenia (odstawienia) od wartości zapotrzebowania, a ściślej od liczby JW niezbędnych do jego pokrycia. Bity kodujące stany jednostek w chwilach dużego zapotrzebowania częściej przyjmują wartości 1 od bitów kodujących stany jednostek w chwilach mniejszego zapotrzebowania.
2. Uzależnia częstość wyboru jednostek do załączenia (odstawienia) od ich jednostkowych kosztów zmiennych. Bity kodujące stany jednostek o mniejszym jednostkowym koszcie zmiennym częściej przyjmują wartości 1 od bitów kodujących stany jednostek o większym koszcie jednostkowym, co oznacza, że jednostki bardziej ekonomiczne preferowane są do załączenia częściej, a do odstawienia rzadziej od jednostek mniej ekonomicznych.

3. Uzależnia częstość wyboru jednostek do odstawienia od ich kosztów rozruchu. Bity kodujące stany jednostek o mniejszych kosztach rozruchu częściej przyjmują wartość 0 od bitów kodujących stany jednostek o większych kosztach rozruchu.

W trakcie badań symulacyjnych zauważono, że operator mutacji MB3 w ponad 75% przypadków polepsza przystosowanie mutowanych osobników. W 3840 przypadkach na 5000 prób otrzymano poprawę przystosowania zmutowanych chromosomów (o losowo dobranych genach). Podobne symulacje wykonano dla mutacji MBR, MB1 i MB2. Odsetek mutacji poprawiających i pogarszających rozwiązania zobrażowano histogramem na rys. 4.12.



Rys. 4.12. Histogram obrazujący odsetek mutacji MBR, MB1, MB2 i MB3 w poszczególnych przedziałach procentowej zmiany wartości funkcji kosztu. Źródło: opracowanie własne.

4.4.1.1.3. METODY ELIMINACJI OGRANICZEŃ FUNKCJI KOSZTU

W zadaniu ERO-k dla reprezentacji RB1 zastosowano strategię naprawy chromosomów, strategię z funkcją kary, które szczegółowo omówiono poniżej oraz operatory genetyczne i reprezentacje pozwalające wyeliminować część ograniczeń. ERO metodą równych przyrostów względnych, przy charakterystykach przyrostów względnych $\varepsilon_{ki}(P_{ni})$ zdefiniowanych w podrozdziale 4.3.3, zapewnia spełnienie przez rozwiązania warunków bilansu (4.5) i zakresu generacji JW (4.6), przy założeniu, że spełniają one warunki zakresu generacji grupy JW (4.7) i (4.8).

Strategia naprawy polega na modyfikacji osobników niedopuszczalnych ze względu na warunki zakresu zmienności obciążeń grupy JW (4.7) i (4.8) tak, aby naprawione wersje spełniały te warunki. Osobniki naprawione, które nie spełniają ograniczeń związanych z minimalnym czasem postoju (4.9) lub minimalnym czasem pracy (4.10), są karane w stopniu

zależnym od przekroczenia tych ograniczeń. Strategia kary polega na karaniu osobników za przekroczenie ograniczeń (4.7) lub (4.8) jak i ograniczeń (4.9) lub (4.10).

Strategia naprawy chromosomów niedopuszczalnych SN

W tej strategii kontroli podlegają ograniczenia wynikające z zakresu zmienności obciążeń grupy współpracujących jednostek wytwórczych (4.7) i (4.8). Wprowadza się zbiory:

$\Omega_1(t)$ – zbiór jednostek załączonych w chwili t : $\Omega_1(t) = \{i : \alpha_i(t) = 1\}$,

$\Omega_0(t)$ – zbiór jednostek odstawionych w chwili t : $\Omega_0(t) = \{i : \alpha_i(t) = 0\}$.

Naprawa chromosomów przebiega wg następującego algorytmu (dla $t = 1, 2, \dots, T$):

1. Kontrola warunku (4.7) – suma minimów technicznych pracujących jednostek jest nie większa od zadanego zapotrzebowania w chwili t . Przy naruszeniu tego warunku stosuje się jedną ze strategii naprawy:

1.1. losową – zmienia się stan losowo wybranej jednostki ze zbioru $\Omega_1(t)$ na „odstawiona” (zmiana odpowiedniego bitu w chromosomie z 1 na 0);

1.2. deterministyczną – zmienia się stan najmniej ekonomicznej (o najniższej randze na liście rankingowej) jednostki ze zbioru $\Omega_1(t)$ na „odstawiona”.

Naprawa zachodzi do momentu spełnienia warunku (4.7).

2. Kontrola warunku (4.8) – suma mocy osiągalnych pracujących jednostek jest nie mniejsza od zadanego zapotrzebowania i rezerwy wirującej w chwili t . Jeśli warunek jest naruszony, stosuje się jedną ze strategii naprawy:

2.1. losową – zmienia się stan losowo wybranej jednostki ze zbioru $\Omega_0(t)$ na „załączona” (zmiana odpowiedniego bitu w chromosomie z 0 na 1);

2.2. deterministyczną – zmienia się stan najbardziej ekonomicznej jednostki ze zbioru $\Omega_0(t)$ na „załączona”.

Naprawa zachodzi do momentu spełnienia warunku (4.8).

Pozycję jednostki na liście rankingowej determinuje jednostkowy koszt zmienny wytwarzania przy obciążeniu osiągalnym jednostki. Jeśli charakterystyki kosztów zmiennych jednostek krzyżują się, tzn. w pewnym zakresie obciążeń jednostkę A charakteryzuje mniejszy koszt zmienny od jednostki B , w innym zakresie natomiast jednostka B wykazuje mniejszy koszt zmienny od jednostki A , bezpieczniej używać strategii losowej. Strategię naprawy w wersji losowej oznacza się symbolem SNL, natomiast w wersji deterministycznej – SND.

Osobniki naprawione mogą być używane tylko do wyznaczenia wartości funkcji kosztu, którą przypisuje się ich niedopuszczalnym oryginałom lub mogą zastępować oryginały z pewnym prawdopodobieństwem p_w . W wielu zadaniach optymalizacji kombinatorycznej najlepsze efekty daje wymiana tylko 5% niedopuszczalnych osobników (tzw. reguła 5% [Orv94]). Zapobiega to przedwczesnej eliminacji osobników niedopuszczalnych, które mogą przechowywać wartościowy materiał genetyczny oraz zbieżności algorytmu do superosobników.

Jeśli naprawione osobniki nie spełniają ograniczenia związanego z minimalnym czasem postoju jednostek (4.9) lub minimalnym czasem pracy (4.10), stosuje się dla nich zastępczą funkcję kosztu (4.88).

Strategia z funkcją kary SFK

Zastępcza funkcja kosztu F_p' chromosomów dopuszczalnych ze względu na warunki (4.7) i (4.8) – $ch \in D_1$, a nie spełniających ograniczeń związanych z minimalnym czasem postoju (4.9) lub ograniczeń związanych z minimalnym czasem pracy (4.10) – $ch \notin D_2$, ma postać:

$$F_p'(ch) \Big|_{ch \in D_1 - D_2} = M_1 \left\{ 1 + m_a \sum_{i=1}^N [f_p(i) + f_r(i)] \right\} \quad (4.88)$$

gdzie: D_1 – zbiór osobników w populacji \mathcal{P} dopuszczalnych ze względu na ograniczenia (4.7) i (4.8); D_2 – zbiór osobników w populacji \mathcal{P} dopuszczalnych ze względu na ograniczenia (4.9) i (4.10); M_1 – stała większa od maksymalnej wartości kosztu osobników dopuszczalnych $ch \in D_1 \cap D_2$ wyznaczonego ze wzoru (4.2), przyjęto:

$$M_1 = T \sum_{i=1}^N K_{zi}(P_{n \max i}) \quad (4.89)$$

m_a – współczynnik pozwalający sterować wpływem stopnia naruszenia ograniczeń na wartość funkcji kosztu, określany ze wzoru (4.98); $f_p(i)$ – funkcja dyskretna wyrażająca stopień przekroczenia ograniczenia (4.9):

$$f_p(i) = \sum_{k=1}^{l_{pi}} \left\{ \beta_i(k) [t_{p \min i} - t_{pi}(k)] \right\} \quad (4.90)$$

l_{pi} – liczba okresów, w których jednostka i -ta jest nieprzerwanie odstawiona w okresie optymalizacji T ; $t_{pi}(k)$ – czas postoju jednostki i -tej w k -tym okresie odstawienia; $\beta_i(k)$ – zmienna binarna przyjmująca wartość 1, gdy jednostka i -ta przekracza ograniczenie (4.9) w k -tym okresie odstawienia lub 0, jeśli ograniczenie nie jest naruszone lub nie można wyznaczyć czasu postoju (taka sytuacja zachodzi gdy JW pozostaje w postoju do końca okresu optymalizacji T):

$$\beta_i(k) = \begin{cases} 1, & \text{jeśli } t_{pi}(k) < t_{p \min i} \\ 0, & \text{jeśli } t_{pi}(k) \geq t_{p \min i} \vee \tau_{ri}(k) > T \end{cases} \quad (4.91)$$

$\tau_{ri}(k)$ – godzina rozruchu jednostki i -tej po k -tym okresie postoju; $f_r(i)$ – funkcja dyskretna wyrażająca stopień przekroczenia ograniczenia (4.10):

$$f_r(i) = \sum_{k=1}^{l_{ri}} \{\gamma_i(k)[t_{r\min i} - t_{ri}(k)]\} \quad (4.92)$$

l_{ri} – liczba okresów, w których jednostka i -ta jest nieprzerwanie w ruchu w okresie optymalizacji T ; $t_{ri}(k)$ – czas pracy jednostki i -tej w k -tym okresie pracy; $\gamma_i(k)$ – zmienna binarna przyjmująca wartość 1, gdy jednostka i -ta przekracza ograniczenie (4.10) w k -tym okresie pracy lub 0, jeśli ograniczenie nie jest naruszone lub nie można wyznaczyć czasu pracy jednostki (taka sytuacja zachodzi w przypadku pozostania jednostki w ruchu do końca okresu optymalizacji T):

$$\gamma_i(k) = \begin{cases} 1 & \text{jeśli } t_{ri}(k) < t_{r\min i} \\ 0 & \text{jeśli } t_{ri}(k) \geq t_{r\min i} \vee \tau_{oi}(k) > T \end{cases} \quad (4.93)$$

$\tau_{oi}(k)$ – godzina odstawienia jednostki i -tej po k -tym okresie pracy.

Zastępcza funkcja kosztu (4.88) zapewnia gorszą ocenę osobników niedopuszczalnych ze względu na warunki (4.9) i (4.10) od osobników dopuszczalnych. Funkcja ta zależna jest liniowo od stopnia przekroczenia ograniczeń (4.9) i (4.10). W początkowej fazie procesu ewolucyjnego każdy osobnik wielokrotnie przekracza ograniczenia (4.9) i (4.10). Ponieważ wtedy oceny osobników uzależnione są tylko od stopnia przekroczeń tych ograniczeń, stopień ten jest minimalizowany przez AE. W pewnym momencie procesu pojawiają się osobniki dopuszczalne ze względu na ograniczenia (4.9) i (4.10) i zaczynają dominować w populacji. Ponieważ nie stosuje się tutaj selekcji proporcjonalnej (np. koła ruletki), lecz turniej binarny, dominacja nie jest zbyt silna, co pozwala uniknąć przedwczesnej zbieżności populacji do superosobnika. W dalszych fazach procesu pojawia się coraz więcej osobników dopuszczalnych $ch \in D_1 \cap D_2$, a miarą ich oceny jest wartość funkcji kosztu (4.2).

Osobniki nie spełniające ograniczeń zakresu zmienności obciążenia grupy jednostek (4.7) i (4.8), niezależnie od tego czy spełniają ograniczenia (4.9) i (4.10), ocenia się stosując zastępczą funkcję kosztu obejmującą składnik kary:

$$F_p'(ch) \Big|_{ch \notin D_1} = M_2 \left[1 + m_b \sum_{t=1}^T f_d(t) \right] \quad (4.94)$$

gdzie: M_2 – stała większa od maksymalnej wartości kosztu osobników $ch \in D_1 - D_2$ wyznaczonego ze wzoru (4.88), przyjęto:

$$M_2 = M_1 \left\{ 1 + m_a \frac{T}{2} \sum_{i=1}^N [(t_{p_{\min i}} - 1) + (t_{r_{\min i}} - 1)] \right\} \quad (4.95)$$

m_b – współczynnik sterujący wpływem stopnia naruszenia ograniczeń na wartość funkcji kosztu ($m_b > 0$), określany ze wzoru (4.100a) lub (4.100b); $f_d(t)$ – funkcja wyrażająca stopień przekroczenia ograniczeń (4.7) i (4.8), określona wzorem:

$$f_d(t) = \begin{cases} \sum_{i \in \Omega_1(t)} P_{n_{\min i}} - P_z(t), & \text{jeśli } \sum_{i \in \Omega_1(t)} P_{n_{\min i}} > P_z(t) \\ P_z(t) + P_{rw}(t) - \sum_{i \in \Omega_1(t)} P_{n_{\max i}}, & \text{jeśli } P_z(t) + P_{rw}(t) > \sum_{i \in \Omega_1(t)} P_{n_{\max i}} \\ 0 & \text{w innych przypadkach} \end{cases} \quad (4.96a)$$

lub, jeśli JW mają podobne zakresy generacji:

$$f_d(t) = \begin{cases} l_{j_{\min}}(t) - l_{j_1}(t), & \text{jeśli } l_{j_1}(t) < l_{j_{\min}}(t) \\ l_{j_1}(t) - l_{j_{\max}}(t), & \text{jeśli } l_{j_1}(t) > l_{j_{\max}}(t) \\ 0 & \text{w innych przypadkach} \end{cases} \quad (4.96b)$$

$\Omega_1(t)$, $l_{j_1}(t)$ – odpowiednio zbiór i liczba jednostek załączonych w chwili t ; $l_{j_{\min}}(t)$, $l_{j_{\max}}(t)$ – minimalna i maksymalna liczba jednostek potrzebnych do pokrycia zapotrzebowania w chwili t , określana ze wzorów (4.73) i (4.74).

Definicja funkcji kosztu (4.94) zapewnia gorszą ocenę osobnika $ch \notin D_1$ od jakiegokolwiek $ch \in D_1$. Osobniki naruszające warunki (4.7) i (4.8) są zawsze gorzej oceniane niż osobniki naruszające warunki (4.9) i (4.10), co zapewnia wcześniejszą eliminację takich osobników z populacji. Zależność kosztu od stopnia przekroczenia ograniczenia, który wyraża się w funkcji f_d , jest liniowa. W początkowej fazie procesu algorytm, z uwagi na brak rozwiązań $ch \in D_1$, minimalizuje stopień przekroczeń warunków (4.7) i (4.8). Po znalezieniu rozwiązań $ch \in D_1$ ocenia się je stosując funkcję (4.88) i dalej działają mechanizmy przedstawione powyżej, przy opisywaniu tej funkcji.

Współczynniki m_a oraz m_b we wzorach (4.88) i (4.94) dobiera się w ten sposób, aby zapewnić jednakową szerokość zakresów zmienności funkcji kosztu dla rozwiązań dopuszczalnych i niedopuszczalnych: $\max\{F'_P(ch)\big|_{ch \notin D_1}\} - \min\{F'_P(ch)\big|_{ch \in D_1}\} \approx \max\{F'_P(ch)\big|_{ch \in D_1 - D_2}\} - \min\{F'_P(ch)\big|_{ch \in D_1 - D_2}\} \approx \max\{F'_P(ch)\big|_{ch \in D_1 \cap D_2}\} - \min\{F'_P(ch)\big|_{ch \in D_1 \cap D_2}\}$. Szerokość zakresu zmienności dla zastępczej funkcji kosztu (4.88) wynosi:

$$\begin{aligned} & \max\{F'_P(ch)\big|_{ch \in D_1 - D_2}\} - \min\{F'_P(ch)\big|_{ch \in D_1 - D_2}\} = M_2 - M_1 = \\ & = M_1 m_a \frac{T}{2} \sum_{i=1}^N [(t_{p \min i} - 1) + (t_{r \min i} - 1)] \end{aligned} \quad (4.97)$$

Stąd, po uwzględnieniu warunku równości zakresów zmienności, otrzymuje się wzór na współczynnik m_a :

$$m_a = \frac{\max\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\} - \min\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\}}{M_1 \frac{T}{2} \sum_{i=1}^N [(t_{p \min i} - 1) + (t_{r \min i} - 1)]} = \frac{M_1 - \widehat{F}_{P \min}}{M_1 \frac{T}{2} \sum_{i=1}^N [(t_{p \min i} - 1) + (t_{r \min i} - 1)]} \quad (4.98)$$

gdzie: $\widehat{F}_{P \min}$ – spodziewane minimum funkcji kosztu (4.2) (dla zadania zdefiniowanego w podrozdziale 4.1 przyjęto $\widehat{F}_{P \min} = 2,58 \cdot 10^6$ zł).

Potencjalnie maksymalna wartość zastępczej funkcji kosztu (4.94) zostanie osiągnięta, jeśli $\forall t: f_d(t) = P_z(t) + P_{rw}(t)$, przy definicji $f_d(t)$ wzorem (4.96a) lub $\forall t: f_d(t) = N$, przy definicji $f_d(t)$ wzorem (4.96b), stąd:

$$\max\{F'_P(ch)\big|_{ch \in D_1}\} - \min\{F'_P(ch)\big|_{ch \in D_1}\} = M_2 m_b \sum_{t=1}^T [P_z(t) + P_{rw}(t)] \quad (4.99a)$$

lub

$$\max\{F'_P(ch)\big|_{ch \in D_1}\} - \min\{F'_P(ch)\big|_{ch \in D_1}\} = M_2 m_b TN \quad (4.99b)$$

Wobec powyższego i warunku równości szerokości zakresów zmienności, wzór na m_b przebiera postać (4.100a), przy definicji $f_d(t)$ wzorem (4.94a) lub (4.100b), przy definicji $f_d(t)$ wzorem (4.94b) :


$$m_b = \frac{\max\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\} - \min\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\}}{M_2 TN} = \frac{M_1 - \widehat{F}_{P \min}}{M_2 TN} \quad (4.100a)$$

$$m_b = \frac{\max\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\} - \min\{F_P(ch)\big|_{ch \in D_1 \cap D_2}\}}{M_2 \sum_{t=1}^T [P_z(t) + P_{rw}(t)]} = \frac{M_1 - \widehat{F}_{P \min}}{M_2 \sum_{t=1}^T [P_z(t) + P_{rw}(t)]} \quad (4.100b)$$

4.4.1.2. ALGORYTM Z BINARNĄ REPREZENTACJĄ MOMENTÓW ODSTAWIEŃ I ZAŁĄCZEŃ

4.4.1.2.1. REPREZENTACJA ZMIENNYCH RB2

Chromosomy kodują dyskretne chwile odstawień g_{om} i załączeń g_{zn} jednostek. Przyjmuje się, że odstawienie JW może nastąpić tylko w przedziałach czasowych $\langle t_{som}, t_{kom} \rangle$, w których przebieg zapotrzebowania jest malejący, natomiast załączenie – w przedziałach $\langle t_{szn}, t_{kzn} \rangle$, w których przebieg zapotrzebowania jest rosnący (przy czym: $t_{som}, t_{kom}, t_{szn}, t_{kzn} \in \{1, 2, \dots, 24\}$; indeks m oznacza numer przedziału czasowego odstawień, n – numer przedziału czasowego załączeń). Dla zadanego przebiegu zapotrzebowania przyjęto dwa przedziały załączeń ($n \in \{1, 2\}$) i trzy przedziały odstawień ($m \in \{1, 2, 3\}$) zilustrowane na rys. 4.13.



Rys. 4.13. Przedziały czasowe odstawień i załączeń jednostek dla przyjętego przebiegu zapotrzebowania $P_z(t)$. Źródło: opracowanie własne.

Dodatkowo przyjmuje się następujące założenia, które pozwalają uwzględnić wszystkie możliwe w praktyce harmonogramy pracy jednostek oraz ich stany początkowe:

1. Jeżeli w m -tym przedziale odstawień nie nastąpi odstawienie jednostki, zmienna g_{om} przyjmuje umowną wartość $(t_{kom} + 1)$. W takich przypadkach zakłada się, że odstawienie następuje w pierwszej godzinie sąsiedniego przedziału załączeń – t_{kzn} , chyba, że zmienna g_{zn} , oznaczająca godzinę załączenia JW w tym przedziale, przyjmuje również wartość t_{kzn} . Oznacza to, że JW pozostaje w ruchu w rozważanym przedziale odstawień i następującym po nim przedziale załączeń. Jeśli rozważany przedział odstawień jest ostatnim przedziałem w okresie optymalizacji T , a zmienna $g_{om} = (T+1)$, oznacza to, że jednostka pozostaje w ruchu do końca okresu T .
2. Jeżeli w n -tym przedziale załączeń nie nastąpi załączenie jednostki, zmienna g_{zn} przyjmuje umowną wartość $(t_{kzn} + 1)$ i zakłada się, że odstawienie nastąpi w pierwszej godzinie kolejnego przedziału odstawień – t_{kom} , chyba, że zmienna g_{om} w tym przedziale odstawień również równa jest t_{kom} . Taka sytuacja interpretowana jest jako pozostanie JW w rezerwie w rozważanym przedziale załączeń i następującym po nim przedziale odstawień. Jeśli rozważany przedział załączeń jest ostatnim przedziałem w okresie T , a zmienna $g_{zn} = (T+1)$, oznacza to, że jednostka pozostaje w rezerwie do końca okresu T .
3. Jeśli pierwszym przedziałem w okresie optymalizacji T jest przedział odstawień oraz JW w godzinach bezpośrednio poprzedzających okres T znajduje się w rezerwie (wynika to ze

stanu początkowego t_{psi}), a zmienna $g_{o1} = 1$, oznacza to, że jednostka nadal pozostaje w rezerwie, a jej rozruch może nastąpić w którymś z przedziałów załączeń. Jeśli jednak $g_{o1} \neq 1$, zakłada się, że rozruch jednostki następuje w chwili $t = 1$, a jej odstawienie w chwili g_{o1} .

4. Jeśli pierwszym przedziałem w okresie T jest przedział załączeń oraz JW w godzinach bezpośrednio poprzedzających okres T znajduje się w ruchu, a zmienna $g_{z1} = 1$, oznacza to, że jednostka nadal pozostaje w ruchu, a jej odstawienie może nastąpić w którymś z przedziałów odstawień. Jeśli jednak $g_{z1} \neq 1$, zakłada się, że jednostka jest odstawiana w chwili $t = 1$, a jej rozruch następuje w chwili g_{z1} .

Zmienne g_{om} i g_{zn} , w określonym w podrozdz. 4.1 zadaniu, mogą przybierać następujące wartości:

$$g_{o1} \in \Phi_a = \{t_{so1}, \dots, t_{ko1} + 1\} \quad (4.101)$$

$$g_{z1} \in \Phi_b = \{t_{sz1}, \dots, t_{kz1} + 1\} \quad (4.102)$$

$$g_{o2} \in \Phi_c = \{t_{so2}, \dots, t_{ko2} + 1\} \quad (4.103)$$

$$g_{z2} \in \Phi_d = \{t_{sz2}, \dots, t_{kz2} + 1\} \quad (4.104)$$

$$g_{o3} \in \Phi_e = \{t_{so3}, \dots, t_{ko3} + 1\} \quad (4.105)$$

gdzie: Φ_x – zbiory wartości przyjmowanych przez poszczególne zmienne ($x = \{a, b, c, d, e\}$); $t_{so1} = 1$, $t_{ko1} = 4$, $t_{sz1} = 5$, $t_{kz1} = 13$, $t_{so2} = 14$, $t_{ko2} = 15$, $t_{sz2} = 16$, $t_{kz2} = 18$, $t_{so3} = 19$, $t_{ko3} = 24$.
Wartości zmiennych g_{om} i g_{zn} dla różnych harmonogramów pracy JW przedstawiono poniżej.

Tablica 4.6. Wartości zmiennych g_{om} i g_{zn} dla różnych harmonogramów pracy JW. Źródło: opracowanie własne.

Harmonogram	g_{o1}	g_{z1}	g_{o2}	g_{z2}	g_{o3}
odstawienie na dolinę nocną	1, ..., 4	5, ..., 13	16	16	25
	5	5	16	16	19, ..., 24
odstawienie na dolinę popołudniową	5	5	14, 15	16, ..., 18	25
dwa odstawienia	1, ..., 4	5, ..., 13	14, 15	16, ..., 18	25
	5	5	14, 15	16, ..., 18	19, ..., 24
załączenie na jeden szczyt	1	14	14	16, ..., 18	19, ..., 24
	1	5, ..., 13	14, 15	19	19
załączenie na dwa szczyty	1	5, ..., 13	14, 15	16, ..., 18	19, ..., 24
praca bez odstawień	5	5	16	16	25
pozostanie w rezerwie	1	14	14	19	19

Każdą zmienną g_{om} i g_{zn} koduje się binarnie w postaci łańcucha B o długości zależnej od zakresu jej zmienności. Przykładowo do zakodowania zmiennej $g_{o1} \in \{1, 2, \dots, 5\}$

(pięciowartościowej) potrzeba trzech bitów. Pojawia się tu redundancja wynikająca z tego, że na trzech bitach można zakodować osiem wartości. Taka nadmiarowość ma odpowiednik w naturze: trójelementowe kodony w łańcuchach DNA, złożone z czterech typów nukleotydów (co daje 64 kombinacje), kodują dwadzieścia typów aminokwasów budujących białka [Ber97]. W związku z tym kilka kodonów może kodować to samo białko. Redundancje spowodowana kodowaniem binarnym usuwa się w ten sposób, że niektórym wartościom zmiennej g przypisuje się dwie wartości łańcucha B , leżące w sąsiedztwie topologicznym. Do kodowania zastosowano kod Graya, który ma tę właściwość, że dwa punkty leżące obok siebie w przestrzeni zadania (w tym przypadku również punkty pokrywające się) różnią się tylko jednym bitem. W tablicy 4.7 podano rozmiary łańcuchów B , ich wartości dziesiętne (wynikające z konwencjonalnego zapisu liczb dziesiętnych w systemie dwójkowym) oraz odpowiadające im wartości zmiennych g_{om} i g_{zn} .

Tablica 4.7. Wartości dziesiętne łańcuchów binarnych B oraz odpowiadające im wartości zmiennych g_{om} i g_{zn} . Źródło: opracowanie własne.

Zmienna	Symbol łańcucha	Liczba bitów kodujących zmienną	Wartość dziesiętna łańcucha B															
			0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
g_{o1}	B_a	3	1	1	2	2	5	5	3	4								
g_{z1}	B_b	4	5	5	6	6	8	8	7	7	14	14	12	13	9	9	11	10
g_{o2}	B_c	2	14	15	16	16												
g_{z2}	B_d	2	16	17	19	18												
g_{o3}	B_e	3	19	20	22	21	25	25	23	24								

Połączone łańcuchy B , reprezentujące zmienne dla kolejnych jednostek, tworzą chromosom (tab. 4.8). Dla zadania z liczbą jednostek $N = 12$ i horyzontem optymalizacji $T = 24$ h, chromosom składa się ze 168 bitów, przy czym do zakodowania harmonogramu pracy jednej jednostki wymaga się 14-tu bitów.

Tablica 4.8. Sposób kodowania w algorytmie z binarną reprezentacją momentów odstawień i załączeń. Źródło: opracowanie własne.

Postać chromosomu:	$B_a(1)$	$B_b(1)$	$B_c(1)$	$B_d(1)$	$B_e(1)$	$B_a(2)$	$B_b(2)$...	$B_e(2)$...	$B_a(N)$	$B_b(N)$...	$B_e(N)$
Przykładowy chromosom:	101	0111	01	00	100	000	1001	...	011	...	001	1101	...	000
Znaczenie genów:	$g_{o1}(1)$	$g_{z1}(1)$	$g_{o2}(1)$	$g_{z2}(1)$	$g_{o3}(1)$	$g_{o1}(2)$	$g_{z1}(2)$...	$g_{o3}(2)$...	$g_{o1}(N)$	$g_{z1}(N)$...	$g_{o3}(N)$

gdzie: $B(i)$ – łańcuch binarny kodujący wartość zmiennej g_{om} lub g_{zn} dla jednostki i -tej; $g_{om}(i)$, $g_{zn}(i)$ – wartości zmiennych dla jednostki i -tej.

4.4.1.2.2. OPERATORY. METODY ELIMINACJI OGRANICZEŃ FUNKCJI KOSZTU

Dla reprezentacji binarnej momentów odstawień i załączeń jednostek stosuje się mutację równomierną MBR, krzyżowanie jednopunktowe K1P, wielopunktowe KWP i jednorodnie KJR oraz transpozycję. Metodą selekcji jest turniej binarny. Operatory te opisano w podrozdziale 4.4.1.1.2.

Dla chromosomów naruszających ograniczenia (4.7), (4.8), (4.9) lub (4.10) stosuje się strategię z funkcją kary zaprezentowaną w podrozdziale 4.4.1.1.3.

4.4.1.3. ALGORYTM Z CAŁKOWITOLICZBOWĄ REPREZENTACJĄ MOMENTÓW ODSTAWIEŃ I ZAŁĄCZEŃ

4.4.1.3.1. REPREZENTACJA ZMIENNYCH RC

Zmienne – czasy odstawień g_{om} i załączeń g_{zn} JW – reprezentowane są w postaci liczb całkowitych. Założenia, co do ustalania przedziałów odstawień i załączeń oraz wartości zmiennych g_{om} i g_{zn} oraz ich interpretacji, poczynione przy omawianiu binarnej reprezentacji momentów odstawień i rozruchów w podrozdz. 4.4.1.2.1, są aktualne. Chromosom składa się z liczb całkowitych c reprezentujących zmienne g_{om} i g_{zn} . Zakresy zmienności genów pokrywają się zakresami zmienności (4.101) ÷ (4.105). Sposób kodowania przedstawiono w tabelicy 4.9. Dla rozpatrywanej liczby jednostek $N = 12$ i horyzontu optymalizacji $T = 24$ h chromosom składa się z 60 genów (liczb całkowitych).

Tablica 4.9. Sposób kodowania w algorytmie z całkowitoliczbową reprezentacją momentów odstawień i załączeń. Źródło: opracowanie własne.

Postać chromosomu:	$c_a(1)$	$c_b(1)$	$c_c(1)$	$c_d(1)$	$c_e(1)$	$c_a(2)$	$c_b(2)$...	$c_e(2)$...	$c_a(N)$	$c_b(N)$...	$c_e(N)$
Przykładowy chromosom:	2	11	15	17	22	1	14	...	23	...	5	5	...	25
Znaczenie genów:	$g_{o1}(1)$	$g_{z1}(1)$	$g_{o2}(1)$	$g_{z2}(1)$	$g_{o3}(1)$	$g_{o1}(2)$	$g_{z1}(2)$...	$g_{o3}(2)$...	$g_{o1}(N)$	$g_{z1}(N)$...	$g_{o3}(N)$

gdzie: $c(i)$ – liczba całkowita reprezentująca wartość zmiennej $g_{om}(i)$ lub $g_{zn}(i)$ dla jednostki i -tej: $c_a(i) \in \Phi_a$, $c_b(i) \in \Phi_b$, $c_c(i) \in \Phi_c$, $c_d(i) \in \Phi_d$, $c_e(i) \in \Phi_e$.

4.4.1.3.2. OPERATORY. METODY ELIMINACJI OGRANICZEŃ FUNKCJI KOSZTU

Dla reprezentacji RC stosuje się następujące operatory genetyczne:

- krzyżowanie jednopunktowe K1P – analogiczne do krzyżowania jednopunktowego w wersji binarnej (punkty cięcia wypadają między genami),
- krzyżowanie wielopunktowe KWP – analogiczne do krzyżowania wielopunktowego w wersji binarnej,
- krzyżowanie całkowitoliczbowe jednorodnie KCJ – analogiczne do krzyżowania jednorodnego w wersji binarnej,

- krzyżowanie całkowitoliczbowe arytmetyczne KCA,
- krzyżowanie całkowitoliczbowe heurystyczne KCH,
- mutację całkowitoliczbową równomierną MCR – analogiczną do mutacji równomiernej w wersji binarnej (mutacja MCR polega na zmianie wartości wybranego losowo z populacji genu na losową wartość całkowitą z zakresu jego zmienności),
- mutację całkowitoliczbową nierównomierną MCN,
- transpozycję – analogiczną do transpozycji w wersji binarnej.

Dla wylosowanej pary rodziców $ch_u = [c_a^u(1), c_b^u(1), \dots, c_e^u(N)]$ i $ch_v = [c_a^v(1), c_b^v(1), \dots, c_e^v(N)]$ krzyżowanie zachodzi z prawdopodobieństwem p_k . Metodą selekcji jest turniej binarny. W przypadku chromosomów nie spełniających ograniczeń (4.7), (4.8), (4.9) lub (4.10) stosuje się strategię z funkcją kary opisaną w podrozdziale 4.4.1.1.3.

Opisane poniżej niestandardowe metody krzyżowania i mutacji, w celu zwiększenia czytelności, zdefiniowano dla pięciu przedziałów czasowych odstawień i załączeń: $\Phi_a, \Phi_b, \dots, \Phi_e$, chociaż można je uogólnić na większą liczbę przedziałów.

Krzyżowanie arytmetyczne w wersji całkowitoliczbowej KCA

W krzyżowaniu arytmetycznym wprowadza się wektory $\mathbf{u} = [u_a(1), u_b(1), \dots, u_e(N)]$ i $\mathbf{v} = [v_a(1), v_b(1), \dots, v_e(N)]$ o składowych zdefiniowanych następująco:

$$u_x(k) = \begin{cases} c_x^u(k), & \text{jeśli } c_x^u(k) = c_x^v(k) \\ c_x^u(k) - 0,499, & \text{jeśli } c_x^u(k) < c_x^v(k) \\ c_x^u(k) + 0,499, & \text{jeśli } c_x^u(k) > c_x^v(k) \end{cases} \quad (4.106)$$

$$v_x(k) = \begin{cases} c_x^v(k), & \text{jeśli } c_x^v(k) = c_x^u(k) \\ c_x^v(k) - 0,499, & \text{jeśli } c_x^v(k) < c_x^u(k) \\ c_x^v(k) + 0,499, & \text{jeśli } c_x^v(k) > c_x^u(k) \end{cases} \quad (4.107)$$

gdzie: $x = \{a, b, c, d, e\}$; $k = 1, 2, \dots, N$.

Potomkowie wyznaczani są poprzez kombinacje liniowe wektorów \mathbf{u} i \mathbf{v} :

$$ch_u' = \text{round}[r_r \mathbf{u} + (1 - r_r) \mathbf{v}] \quad (4.108)$$

$$ch_v' = \text{round}[r_r \mathbf{v} + (1 - r_r) \mathbf{u}] \quad (4.109)$$

gdzie: r_r – liczba rzeczywista losowana z zakresu $(0, 1)$; $\text{round}(\cdot)$ – operator zaokrąglania do najbliższej liczby całkowitej, działający na każdej składowej kombinacji liniowych.

Wprowadzenie wartości $\pm 0,499$ we wzorach (4.106) i (4.107) zapewnia, że prawdopodobieństwa przyjęcia przez geny osobników potomnych wartości z przedziału

$\langle c_x^u(k), c_x^v(k) \rangle$ są jednakowe (rys. 4.14 a)). Zakres zmienności losowej liczby r_r gwarantuje, że rozwiązania reprezentowane przez chromosomy potomne leżą w obszarze dopuszczalnym ze względu na zakres zmienności genów $c_x(k)$, jeżeli tylko chromosomy rodzicielskie były dopuszczalne.

Na rys. 4.14 a) pokazano wartości genów chromosomów potomnych w zależności od wylosowanej liczby r_r . Krzyżowanie arytmetyczne realizuje funkcja KRZYZ_CAR.m.

Krzyżowanie heurystyczne w wersji całkowitoliczbowej KCH

W odróżnieniu od innych operatorów krzyżowania, operator krzyżowania heurystycznego korzysta z informacji o przystosowaniach osobników rodzicielskich ch_u oraz ch_v i tworzy tylko jednego potomka ch' . Rodzice wybierani są z populacji losowo. Wprowadza się wektory $\mathbf{u} = [u_a(1), u_b(1), \dots, u_e(N)]$ i $\mathbf{v} = [v_a(1), v_b(1), \dots, v_e(N)]$ o składowych określonych następująco:

$$u_x(k) = \begin{cases} c_x^u(k), & \text{jeśli } c_x^u(k) = c_x^v(k) \\ c_x^u(k) + 0,499, & \text{jeśli } c_x^u(k) < c_x^v(k) \\ c_x^u(k) - 0,499, & \text{jeśli } c_x^u(k) > c_x^v(k) \end{cases} \quad (4.110)$$

$$v_x(k) = \begin{cases} c_x^v(k), & \text{jeśli } c_x^v(k) = c_x^u(k) \\ c_x^v(k) - 1,497, & \text{jeśli } c_x^v(k) < c_x^u(k) \\ c_x^v(k) + 1,497, & \text{jeśli } c_x^v(k) > c_x^u(k) \end{cases} \quad (4.111)$$

gdzie: $x = \{a, b, c, d, e\}; k = 1, 2, \dots, N$.

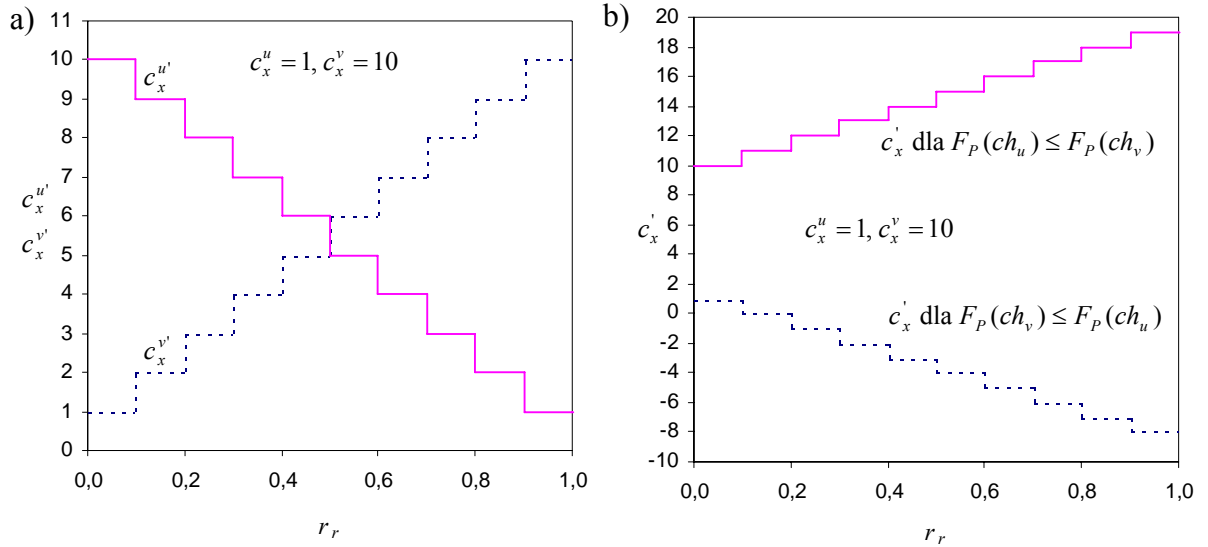
Jeśli rodzic ch_u jest nie gorszy od ch_v (tzn. $F_p(ch_u) \leq F_p(ch_v)$ w zadaniu minimalizacji), osobnik potomny wyznaczany jest zgodnie ze wzorem:

$$ch' = \text{round}[\mathbf{u} + r_r(\mathbf{u} - \mathbf{v})] \quad (4.112)$$

gdzie: r_r – liczba rzeczywista losowana z zakresu $\langle 0, 1 \rangle$.

W przypadku utworzenia potomka ch' , który jest niedopuszczalny ze względu na zakres zmienności genów $c_x(k)$, generuje się inną liczbę losową r_r . Jeśli po l_p próbach (przyjęto $l_p = 10$) operator nie znajduje dopuszczalnego chromosomu, wybiera się inną parę rodziców.

Na rys. 4.14 b) pokazano wartości genów chromosomu potomnego w zależności od wylosowanej liczby r_r . Ten rodzaj krzyżowanie zaimplementowano w funkcji KRZYZ_CHE.m.



Rys. 4.14. Wartości genów chromosomów potomnych względem genów rodzicielskich $c_x^u = 1$ i $c_x^v = 10$ po krzyżowaniu a) arytmetycznym całkowitoliczbowym i b) heurystycznym całkowitoliczbowym, w zależności od r_r . Źródło: opracowanie własne.

Mutacja całkowitoliczbowa nierównomierna MCN

Ten rodzaj mutacji dynamicznej uzależnia „rozpiętość” mutacji od zaawansowania procesu ewolucyjnego. W początkowej fazie procesu przestrzeń rozwiązań przeszukiwana jest globalnie (w całym zakresie zmienności parametrów), podczas gdy w fazie końcowej intensywniej przeszukiwane są obszary w pobliżu znalezionych wcześniej rozwiązań.

Wybrany do mutacji gen $c_x(i)$ chromosomu ch zmienia wartość wg wzoru:

$$c_x'(i) = \begin{cases} c_x(i) + f_{\Delta}(l_{gen}, \max\{\Phi_x\} - c_x(i)), & \text{jeśli } r_b = 0 \\ c_x(i) - f_{\Delta}(l_{gen}, c_x(i) - \min\{\Phi_x\}), & \text{jeśli } r_b = 1 \end{cases} \quad (4.113)$$


gdzie: l_{gen} – licznik generacji, $l_{gen} = 1, 2, \dots, L_{gen}$; L_{gen} – maksymalna liczba generacji algorytmu; $\min\{\Phi_x\}$, $\max\{\Phi_x\}$ – dolne i górne ograniczenie zakresu zmienności genu $c_x(i)$ (4.101) ÷ (4.105).

Funkcja $f_{\Delta}(l_{gen}, y)$ przyjmuje wartości całkowite z zakresu $1 \div y$, przy czym prawdopodobieństwo, że $f_{\Delta}(l_{gen}, y)$ jest bliskie 1 wzrasta ze wzrostem l_{gen} . Zastosowano funkcję postaci:

$$f_{\Delta}(l_{gen}, y) = \text{round} \left\{ (y - 0,002) \left[1 - r_r^{(1-l_{gen}/L_{gen})^n} \right] + 0,501 \right\} \quad (4.114)$$

gdzie: r_r – liczba rzeczywista losowana z zakresu $\langle 0, 1 \rangle$; n – parametr określający stopień zależności od licznika generacji, przyjęto $n = 2$.

Przykładowy przebieg funkcji $f_{\Delta}(l_{gen}, y)$ pokazano na rys. 4.15.



Rys. 4.15. Przebieg dyskretnych funkcji $f_{\Delta}(l_{gen}, y)$ dla $n = 2$ i $y = 10$. Źródło: oprac. własne.

Mutację MCN zaimplementowano w funkcji MUTACJA_CN.m.

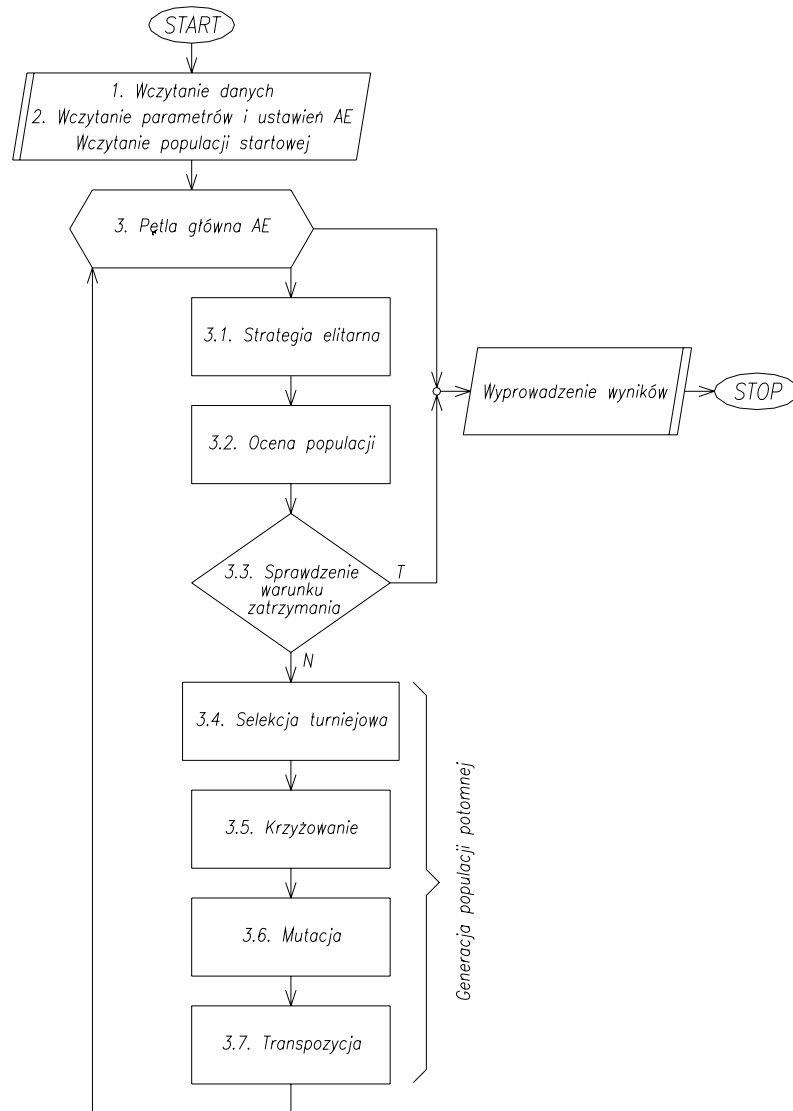
4.4.1.4. SCHEMAT ALGORYTMU OPTIMALIZACYJNEGO

Szczegółowa postać algorytmu ewolucyjnego dla zadania ERO-k na poziomie elektrowni prezentuje się następująco:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych generacji jednostek P_{nmini} i P_{nmaxi} , charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie t_{pmini} i minimalnych czasów pracy po rozruchu t_{rmini} .
2. Określenie parametrów i ustawień algorytmu ewolucyjnego: liczby generacji L_{gen} , liczebności populacji L_{pop} , sposobu reprezentacji zmiennych i parametrów kodowania, sposobu postępowania z osobnikami niedopuszczalnymi, populacji początkowej \mathcal{P}_1 , metody i parametrów mutacji, metody i parametrów krzyżowania, oczekiwanej liczby transpozycji chromosomu w_t , parametrów zastępczych funkcji kosztu, warunku zatrzymania.
3. Dla $l_{gen} = 1$ do L_{gen} lub do momentu spełnienia warunku zatrzymania powtarzaj:
 - 3.1. Jeśli $l_{gen} \neq 1$ włączenie do populacji $\mathcal{P}_{l_{gen}}$ najlepszego osobnika rodzicielskiego z populacji $\mathcal{P}_{(l_{gen}-1)}$.
 - 3.2. Ocena populacji $\mathcal{P}_{l_{gen}}$ (zależna od sposobu postępowania z osobnikami niedopuszczalnymi; a – strategia naprawy, b – strategia karania):

- 3.2.1.a. Naprawa osobników niedopuszczalnych ze względu na ograniczenia związane z zakresem generacji współpracujących jednostek (4.7) i (4.8).
- 3.2.1.b. Wyznaczenie stopnia naruszenia ograniczeń (4.7) i (4.8).
- 3.2.2.a. Ekonomiczny rozdział obciążeń dla naprawionych wersji osobników spełniających ograniczenia (4.9) i (4.10); wyznaczenie kosztów zmiennych dla tych rozwiązań.
- 3.2.2.b. Ekonomiczny rozdział obciążeń dla osobników dopuszczalnych ze względu na ograniczenia (4.7) ÷ (4.10); wyznaczenie dla nich kosztów zmiennych.
- 3.2.3.a. Wyznaczenie kosztów rozruchów dla osobników dopuszczalnych ze względu na ograniczenia (4.9) i (4.10) lub wyznaczenie stopnia naruszenia tych ograniczeń w przypadku osobników, które je naruszają.
- 3.2.3.b. Wyznaczenie kosztów rozruchów dla osobników dopuszczalnych ze względu na warunki (4.7) ÷ (4.10) lub wyznaczenie stopnia naruszenia ograniczeń (4.9) i (4.10) w przypadku osobników spełniających warunki (4.7) i (4.8), a naruszających warunek (4.9) lub (4.10).
- 3.2.4.a.b. Ukaramy osobników niedopuszczalnych ze względu na ograniczenia (4.9) i (4.10) zależne od stopnia przekroczenia tych ograniczeń.
- 3.2.5.a. Wymiana osobników niedopuszczalnych ze względu na warunki (4.7) i (4.8) na ich naprawione wersje z prawdopodobieństwem p_w .
- 3.2.5.b. Ukaramy osobników niedopuszczalnych ze względu na ograniczenia (4.7) i (4.8) zależne od stopnia przekroczenia tych ograniczeń.
- 3.3. Sprawdzenie warunku zatrzymania.
- 3.4. Selekcja turniejowa.
- 3.5. Krzyżowanie.
- 3.6. Mutacja.
- 3.7. Transpozycja.

Schemat blokowy tego algorytmu przedstawiono na rys. 4.16.



Rys. 4.16. Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmów ewolucyjnych – wersja kombinowana. Źródło: opracowanie własne.

4.4.2. ALGORYTMY SYMULOWANEGO WYŻARZANIA

Wprowadzenie do algorytmów symulowanego wyżarzania zamieszczono w dodatku 2.

Metody reprezentacji zmiennych

Zastosowano trzy sposoby reprezentacji zmiennych:

- reprezentacja binarna stanów pracy jednostek RB1 opisana w podrozdziale 4.4.1.1.1,
- reprezentacja binarna momentów odstawień i załączeń RB2 opisana w podrozdziale 4.4.1.2.1,
- reprezentacja całkowitoliczbowa momentów odstawień i załączeń RC opisana w podrozdziale 4.4.1.3.1.

Punkty próbkujące przestrzeń rozwiązań w SW są tożsame z pojedynczymi chromosomami w AE.

Operatory przesunięcia

Operatory przesunięcia pokrywają się z operatorami mutacji oraz transpozycji stosowanymi w algorytmach ewolucyjnych. Operatory te są dostosowane do sposobu reprezentacji zmiennych. Ich zadaniem jest nieznacząca modyfikacja rozwiązania.

Metody eliminacji ograniczeń funkcji kosztu

Rozwiązania niedopuszczalne (punkty startowe i próbne) są naprawiane lub karane według strategii przedstawionych w podrozdziale 4.4.1.1.3. Naprawione punkty próbne zastępują swoje niedopuszczalne wersje z prawdopodobieństwem wymiany p_w . Zastępczą funkcję kosztu punktów $ch \notin D_1$, które nie spełniają ograniczeń zakresu zmienności obciążenia grupy jednostek (4.7) lub (4.8), zdefiniowano wzorem (4.94), przy czym D_1 jest w tym przypadku zbiorem wszystkich punktów dopuszczalnych ze względu na ograniczenia (4.7) i (4.8). Zastępcza funkcja kosztu punktów $ch \in D_1 - D_2$ spełniających ograniczenia (4.7) i (4.8), a nie spełniających ograniczeń związanych z minimalnym czasem postoju (4.9) lub minimalnym czasem pracy (4.10), określona jest wzorem (4.88), gdzie D_2 jest zbiorem wszystkich punktów dopuszczalnych ze względu na ograniczenia (4.9) i (4.10).

Warunek zakończenia działania algorytmu

Algorytm kończy działanie, jeśli liczba iteracji pętli zewnętrznej k osiągnie wartość L_{pz} lub jeśli w kolejnych L iteracjach nie osiąga się poprawy rezultatu. Liczbę iteracji pętli wewnętrznej L_{pw} i zewnętrznej L_{pz} ustala się arbitralnie.

4.4.2.1. SCHEMATY WYŻARZANIA

Schemat Kirkpatricka

Temperatura startowa T_1 jest parametrem ściśle zależnym od zadania i wedle zaleceń autorów [Kir83] powinna być na tyle wysoka, aby zapewnić akceptację wszystkich rozwiązań próbnych. Prawdopodobieństwo akceptacji punktów próbnych gorszych od bieżących pod koniec procesu wyżarzania zbliża się do zera.

Temperatura na kolejnych poziomach temperaturowych k zmienia się zgodnie z postępowaniem geometrycznym [Kir83]:

$$T_{k+1} = r_T T_k \quad k = 1, 2, \dots, (L_{pz} - 1) \quad (4.115)$$

w którym: r_T jest współczynnikiem redukcji temperatury przyjmującym najczęściej wartości z zakresu $0,8 \div 0,99\dots$; L_{pz} – liczba iteracji pętli zewnętrznej algorytmu SW.

Zakładając dla temperatury startowej T_1 prawdopodobieństwo akceptacji najgorszego rozwiązania próbnego $p_a(\Delta F_{P_{\max}}, T_1) = 0,99$, otrzymujemy:

$$p_a(\Delta F_{P_{\max}}, T_1) = \exp\left(\frac{-\Delta F_{P_{\max}}}{T_1}\right) = 0,99 \rightarrow \frac{\Delta F_{P_{\max}}}{T_1} = -\ln p_a(\Delta F_{P_{\max}}, T_1) \approx 0,01 \quad (4.116)$$

Stąd temperatura początkowa

$$T_1 = 100 \Delta F_{P_{\max}} \quad (4.117)$$

gdzie: $\Delta F_{P_{\max}}$ – największa wartość różnicy kosztów występująca przy przejściu od punktu bieżącego do próbnego.

Przyjęto, że w końcowej fazie procesu, dla $k > k_q = 0,8L_{pz}$, prawdopodobieństwo akceptacji punktu próbnego gorszego od bieżącego o ΔF_{P_q} jest mniejsze od 0,1:

$$p_a(\Delta F_{P_q}, T_{k_q}) = \exp\left(\frac{-\Delta F_{P_q}}{T_{k_q}}\right) = 0,1 \rightarrow \frac{\Delta F_{P_q}}{T_{k_q}} \approx 2,30 \quad (4.118)$$

Stąd temperatura procesu zaawansowanego w 80% wynosi:

$$T_{k_q} = 0,43 \Delta F_{P_q} \quad (4.119)$$

ΔF_{Pq} jest stałą mniejszą od spodziewanej najmniejszej różnicy kosztów między rozwiązaniem bieżącym a próbnym, przyjęto $\Delta F_{Pq} = 10$ zł.

Po przekształceniu wzoru (4.115) mamy:

$$T_{k+1} = r_T^k T_1 \quad k = 1, 2, \dots, (L_{pz} - 1) \quad (4.120)$$

stąd:

$$r_T^{k_q-1} = \frac{T_{k_q}}{T_1} \quad (4.121)$$

Podstawiając (4.117) oraz (4.119) do (4.121) otrzymujemy

$$r_T = \left(0,0043 \frac{\Delta F_{Pq}}{\Delta F_{P\max}} \right)^{\frac{1}{k_q-1}} \quad (4.122)$$

Największa zmiana funkcji kosztu $\Delta F_{P\max}$ nastąpi przy przejściu z punktu dopuszczalnego do punktu niespełniającego ograniczeń. W strategii z naprawą punktów niedopuszczalnych, w najgorszym przypadku, zmiana funkcji kosztu nie będzie większa od wartości $\max\{F'_p(ch)\big|_{ch \in D_1 - D_2}\} - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} \approx M_2 - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\}$, stąd przyjęto:

$$\Delta F_{P\max} = M_2 - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} \quad (4.123)$$

gdzie: M_2 – stała większa od maksymalnej wartości kosztu osobników $ch \in D_1 - D_2$, wyznaczona ze wzoru (4.95).

Minimalną wartość funkcji kosztu osobników dopuszczalnych można określić drogą eksperymentu. Wobec dużej wartości M_2 wystarczy wyznaczyć przybliżoną wartość $\min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} = \widehat{F}_{P\min}$. Dla zadania zdefiniowanego w podrozdziale 4.1 przyjęto $\widehat{F}_{P\min} = 2,58 \cdot 10^6$ zł.

W strategii z funkcją kary zmiana kosztu nie będzie większa od wartości: $\max\{F'_p(ch)\big|_{ch \notin D_1}\} - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\}$, gdzie maksymalna wartość zastępczej funkcji kosztu $F'_p(ch)\big|_{ch \notin D_1}$ jest mniejsza od wartości otrzymanej z (4.94) dla $f_d(t) = P_z(t) + P_{rw}(t)$ lub $f_d(t) = N$ (zależnie od sposobu definicji funkcji $f_d(t)$). Wobec czego w strategii SFK przyjęto:


$$\Delta F_{P\max} = M_2 \left\{ 1 + m_b \sum_{t=1}^T [P_z(t) + P_{rw}(t)] \right\} - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} \quad (4.124a)$$

lub

$$\Delta F_{P\max} = M_2(1 + m_b TN) - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} \quad (4.124b)$$

Wzór (4.124a) obowiązuje dla $f_d(t)$ określonej wzorem (4.96a), natomiast wzór (4.124b) obowiązuje dla $f_d(t)$ określonej wzorem (4.96b).

Wyznaczone w ten sposób parametry schematu Kirkpatricka dla strategii naprawy SN, $L_{pz} = 1000$, $\Delta F_{Pq} = 10$ zł i obliczonej ze wzoru (4.123) wartości $\Delta F_{P_{max}} = 3194018,96$ zł wynoszą: $T_1 = 319401896$, $r_T = 0,97757278$. Natomiast dla strategii kary SFK, obliczonej ze wzoru (4.124b) wartości $\Delta F_{P_{max}} = 4791028,44$ zł i przy pozostałych parametrach jak wyżej otrzymano: $T_1 = 479102844$, $r_T = 0,97707682$. Na rysunku 4.17 pokazano przebieg prawdopodobieństwa akceptacji punktów gorszych od punktów bieżących o $\Delta F_{P_{max}}$ i ΔF_{Pq} .



Rys. 4.17. Prawdopodobieństwo akceptacji punktów próbnych w zależności od ich jakości i zaawansowania procesu wyżarzania. Źródło: opracowanie własne.

Schemat Aartsa

W adaptacyjnym schemacie zaproponowanym przez Aartsa i van Laarhovena [Aar89] (*polynomial – time cooling schedule*) parametry procesu są modyfikowane w trakcie działania algorytmu, zależnie od jego efektywności. Punktem wyjścia do wyznaczenia temperatury startowej było następujące rozumowanie. Temperatura startowa praktycznie zapewnia akceptację wszystkich generowanych rozwiązań próbnych. Niech m_1 oznacza liczbę rozwiązań próbnych, dla których $\Delta F_P \leq 0$, a m_2 liczbę rozwiązań próbnych, dla których $\Delta F_P > 0$. Ponadto niech $\Delta \bar{F}_P^+$ będzie średnią wartością zmiany kosztu liczoną dla tych rozwiązań, dla których $\Delta F_P > 0$. Współczynnik akceptacji χ (stosunek zaakceptowanych rozwiązań próbnych do wszystkich wygenerowanych rozwiązań próbnych) może być aproksymowany przez wyrażenie [Aar89]:

$$\chi \approx \frac{m_1 + m_2 \exp\left(\frac{-\Delta \bar{F}_P^+}{T}\right)}{m_1 + m_2} \quad (4.125)$$

z którego otrzymuje się:

$$T = \frac{\Delta \bar{F}_p^+}{\ln \left(\frac{m_2}{m_2 \chi - m_1 (1 - \chi)} \right)} \quad (4.126)$$

Początkową wartość temperatury otrzymuje się z równania (4.126) w procesie iteracyjnym. Przyjmując $\chi = 0,99$ generuje się punkty próbne do momentu stabilizacji temperatury na poziomie T_1 .

Sposób adaptacji temperatury definiuje wzór [Aar89]:

$$T_{k+1} = \frac{T_k}{1 + \frac{T_k \ln(1 + \delta)}{3\sigma_k}} \quad k = 1, 2, \dots, (L_{pz} - 1) \quad (4.127)$$

w którym: δ – stała (tzw. parametr odległości) określająca stopień korekty temperatury, przyjmująca zwykle wartości z zakresu $0,1 \div 0,5$, przyjęto $\delta = 0,3$; σ_k – odchylenie standardowe różnicy kosztu pomiędzy rozwiązaniem bieżącym a próbnym ΔF_p na k -tym poziomie temperaturowym.

Punkty niedopuszczalne, oceniane za pomocą zastępczych funkcji kosztu ze składnikami kar (4.88) lub (4.94), komplikują dobór temperatury startowej, jej adaptację i cały proces wyżarzania. W strategii z funkcją kary proces wyżarzania przebiega na trzech poziomach kosztowych. Poziom pierwszy obejmuje punkty niedopuszczalne $ch \notin D_1$ oceniane zastępczą funkcją kosztu (4.88). Algorytm operuje na tym poziomie w początkowej fazie działania. Poziom drugi obejmuje punkty niedopuszczalne $ch \in D_1 - D_2$ oceniane zastępczą funkcją kosztu (4.94) i wreszcie poziom trzeci – punkty dopuszczalne $ch \in D_1 \cap D_2$ oceniane funkcją (4.2). Przy przeskokach pomiędzy poziomami (tzn. gdy punkt próbny należy do innego poziomu niż punkt bieżący) pojawiają się znaczne różnice kosztów ΔF_p . Oznacza to mniejszą redukcję temperatury i co za tym idzie utrzymywaniem dużego prawdopodobieństwa akceptacji punktów próbnych należących do tego samego poziomu kosztowego co punkt bieżący. Skutkuje to wydłużeniem procesu wyżarzania i losowym błędzeniem algorytmu. Aby temu zapobiec proponuje się wyznaczać dla każdego poziomu kosztowego indywidualnie dopasowane do niego temperatury.

Największą potencjalną różnicę kosztów pomiędzy rozwiązaniem bieżącym a próbnym $ch \notin D_1$ na poziomie pierwszym – $\Delta F_{p \max}(1)$, można oszacować ze wzoru (4.99a) lub (4.99b). Temperatura startowa zapewniająca akceptację z prawdopodobieństwem $p_a = 0,99$ najgorszego rozwiązania w tym przypadku wynosi:

$$T_1(1) = - \frac{\Delta F_{p \max}(1)}{\ln p_a [\Delta F_{p \max}(1), T_1(1)]} \approx 100 \Delta F_{p \max}(1) \quad (4.128)$$

gdzie: $T_1(1)$ – temperatura startowa na pierwszym poziomie działania algorytmu SW ze strategią kary SFK; M_2 – stała wyznaczona ze wzoru (4.95).

Na poziomie drugim minimalna i maksymalna wartość zastępczej funkcji kosztu punktów $ch \in D_1 - D_2$ wynosi odpowiednio M_1 i M_2 , stąd maksymalna potencjalna różnica ich kosztów:

$$\Delta F_{P_{\max}}(2) = \max\{F'_p(ch)\big|_{ch \in D_1 - D_2}\} - \min\{F'_p(ch)\big|_{ch \in D_1 - D_2}\} = M_2 - M_1 \quad (4.129)$$

gdzie: $\Delta F_{P_{\max}}(2)$ – maksymalna różnica kosztu pomiędzy rozwiązaniem bieżącym a próbnym $ch \in D_1 - D_2$ na drugim poziomie działania algorytmu SW; M_1 – stała wyznaczona ze wzoru (4.89).

Temperatura startowa, która zapewnia akceptację z prawdopodobieństwem 0,99 potencjalnie najgorszego punktu $ch \in D_1 - D_2$ wynosi:

$$T_1(2) = -\frac{\Delta F_{P_{\max}}(2)}{\ln p_a[\Delta F_{P_{\max}}(2), T_1(2)]} \approx 100(M_2 - M_1) \quad (4.130)$$

gdzie: $T_1(2)$ – temperatura startowa na drugim poziomie działania algorytmu SW.

Na trzecim poziomie największa możliwa różnica kosztu pomiędzy punktami dopuszczalnymi $ch \in D_1 \cap D_2$ wynosi:

$$\Delta F_{P_{\max}}(3) = \max\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} - \min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\} \quad (4.131)$$

gdzie: $\Delta F_{P_{\max}}(3)$ – maksymalna różnica kosztu pomiędzy rozwiązaniem bieżącym a próbnym $ch \in D_1 \cap D_2$ na trzecim poziomie działania algorytmu SW.

Największa szacunkowa wartość kosztu punktu dopuszczalnego $\max\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\}$ jest równa M_1 , natomiast za $\min\{F_p(ch)\big|_{ch \in D_1 \cap D_2}\}$ przyjmuje się przewidywaną najmniejszą wartość kosztu (dla zadania określonego w podrozdziale 4.1 przyjęto $\widehat{F}_{P_{\min}} = 2,58 \cdot 10^6$ zł). Stąd temperatura startowa zapewniająca akceptację najgorszego rozwiązania dopuszczalnego z prawdopodobieństwem 0,99 wynosi:

$$T_1(3) = -\frac{\Delta F_{P_{\max}}(3)}{\ln p_a[\Delta F_{P_{\max}}(3), T_1(3)]} \approx 100(M_1 - \widehat{F}_{P_{\min}}) \quad (4.132)$$

gdzie: $T_1(3)$ – temperatura startowa na trzecim poziomie działania algorytmu SW; $\widehat{F}_{P_{\min}}$ – szacowane minimum funkcji kosztu.

W algorytmie SW ze strategią naprawy brak poziomu pierwszego (punkty $ch \notin D_1$ są naprawiane), a temperatury startowe na poziomie drugim i trzecim określa się ze wzorów (4.130) i (4.132).

Dla zadania ERO-k, które zdefiniowano w podrozdziale 4.1, temperatury startowe procesu operującego na poszczególnych poziomach, wyznaczone ze wzorów wyprowadzonych powyżej wynoszą: $T_1(1) = T_1(2) = T_1(3) = 159\,700\,948$.

Adaptacja temperatur na poszczególnych poziomach zachodzi wg wzoru:


$$T_{k+1}(l) = \frac{T_k(l)}{1 + \frac{T_k(l) \ln(1 + \delta)}{3\sigma_k(l)}} \quad (4.133)$$

gdzie: l – wskaźnik poziomu kosztowego, $l \in \{1, 2, 3\}$ dla SFK lub $l \in \{1, 2\}$ dla SN; $\sigma_k(l)$ – odchylenie standardowe kosztu pomiędzy punktami bieżącymi a próbnymi należącymi do poziomu l -tego na k -tym poziomie temperaturowym.

Jeśli na k -tym poziomie temperaturowym nie przetwarzano punktów należących do poziomu l -tego lub punkty te miały jednakowe koszty, temperatura dla tego poziomu kosztowego pozostaje bez zmian: $T_{k+1}(l) = T_k(l)$. Temperatura obowiązująca na poziomie temperaturowym ($k+1$) jest jednakowa dla wszystkich poziomów kosztowych i jest równa aktualnej temperaturze na tym poziomie kosztowym, na którym zakończył się k -ty poziom temperaturowy.

Proces wyżarzania w algorytmie ze strategią kary rozpoczyna się najczęściej na pierwszym poziomie kosztowym, przy temperaturze startowej $T_1(1)$, która na kolejnych poziomach temperaturowych jest modyfikowana zgodnie ze wzorem (4.133). Jeśli znalezione zostaną punkty $ch \in D_1 - D_2$ (co oznacza przeskok do drugiego poziomu kosztowego) modyfikacji podlega także temperatura na tym poziomie kosztowym. Jeśli przeskok do drugiego poziomu kosztowego jest stabilny, tzn. utrzymuje się do końca iteracji pętli wewnętrznej, temperaturą obowiązującą na kolejnym poziomie temperaturowym jest temperatura drugiego poziomu kosztowego. Podobnie, jeśli nastąpi przeskok (z poziomu pierwszego lub drugiego) do poziomu trzeciego, temperatura na tym poziomie jest adaptowana i obowiązuje na kolejnym poziomie temperaturowym, jeśli przeskok jest stabilny. Analogiczne zmiany temperatury zachodzą przy przejściach z wyższych poziomów kosztowych na niższe, co można obserwować w początkowej fazie operowania na poziomach wyższych. W dalszej fazie działania algorytmu przeskoki z poziomów wyższych na niższe są mało prawdopodobne ze względu na zredukowaną temperaturę, która dopasowuje się zawsze do danego poziomu kosztowego. Powyższe rozważania dotyczą również strategii naprawy, przy czym mamy tu do czynienia tylko z drugim i trzecim poziomem kosztowym.

Przykładowy przebieg początkowej fazy procesu wyżarzania wg zaprezentowanego powyżej zmodyfikowanego schematu Aartsa, dla zadania określonego w podrozdziale 4.1, strategii kary SFK, reprezentacji binarnej RB1, z operatorem przesunięcia w postaci mutacji równomiernej MBR oraz transpozycji OT przedstawiono na rys. 4.18.



Rys. 4.18. Przykładowy przebieg procesu wyżarzania wg zmodyfikowanego schematu Aartsa: koszt punktów bieżących oraz temperatura na poszczególnych poziomach temperaturowych.

Źródło: opracowanie własne.

Warto zwrócić uwagę, że mimo dużych wartości temperatur startowych, już przy pierwszej adaptacji zostają one znacznie zredukowane, dopasowując się do specyfiki procesu przeszukiwania przestrzeni rozwiązań na poszczególnych poziomach kosztowych.

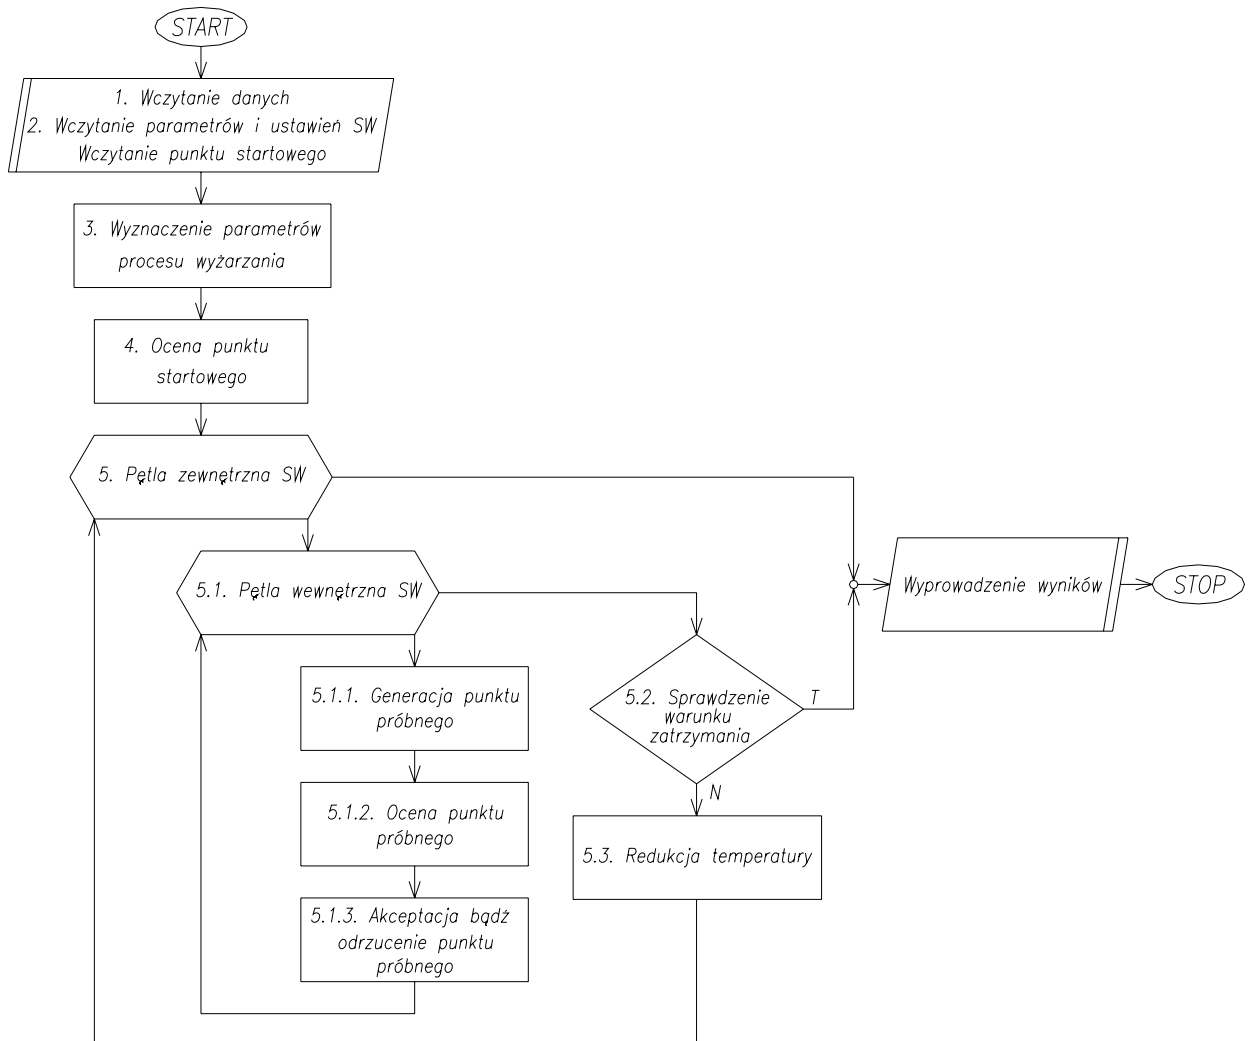
4.4.2.2. SCHEMAT ALGORYTMU OPTIMALIZACYJNEGO

Optymalizacja ERO-k na poziomie elektrowni z wykorzystaniem symulowanego wyżarzania przebiega według następującego algorytmu:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych generacji jednostek $P_{n\text{mini}}$ i $P_{n\text{maxi}}$, charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie $t_{p\text{mini}}$ i minimalnych czasów pracy po rozruchu $t_{r\text{mini}}$.
2. Określenie parametrów i ustawień algorytmu SW: wersji i parametrów schematu wyżarzania, liczby iteracji pętli zewnętrznej L_{pz} i wewnętrznej L_{pw} , sposobu reprezentacji zmiennych i parametrów kodowania, sposobu postępowania z punktami

- niedopuszczalnymi, punktu początkowego ch , metody i parametrów przesunięcia, parametrów zastępczych funkcji kosztu, warunku zatrzymania.
3. Wyznaczenie temperatur początkowych procesu wyżarzania T_1 oraz, w schemacie Kirkpatricka, współczynnika redukcji temperatury r_T .
 4. Ocena punktu początkowego ch (zależna od sposobu postępowania z punktami niedopuszczalnymi; a – strategia naprawy, b – strategia karania):
 - 4.1.a. Naprawa punktu niedopuszczalnego ze względu na ograniczenia związane z zakresem generacji współpracujących jednostek (4.7) i (4.8).
 - 4.1.b. Wyznaczenie stopnia naruszenia ograniczeń (4.7) i (4.8).
 - 4.2.a. Ekonomiczny rozdział obciążeń dla naprawionej wersji punktu spełniającego ograniczenia (4.9) i (4.10); wyznaczenie dla niego kosztu zmiennego.
 - 4.2.b. Ekonomiczny rozdział obciążeń dla punktu dopuszczalnego ze względu na ograniczenia (4.7) ÷ (4.10); wyznaczenie dla niego kosztu zmiennego.
 - 4.3.a. Wyznaczenie kosztów rozruchów dla punktu dopuszczalnego ze względu na ograniczenia związane z minimalnym czasem postoju (4.9) i pracy (4.10) lub wyznaczenie stopnia naruszenia tych ograniczeń w przypadku punktu, który je narusza.
 - 4.3.b. Wyznaczenie kosztów rozruchów dla punktu dopuszczalnego ze względu na warunki (4.7) ÷ (4.10) lub wyznaczenie stopnia naruszenia ograniczeń (4.9) i (4.10) w przypadku punktu spełniającego warunki (4.7) i (4.8), a naruszającego warunek (4.9) lub (4.10).
 - 4.4.a.b. Ukazanie punktu niedopuszczalnego ze względu na ograniczenia (4.9) i (4.10) zależne od stopnia przekroczenia tych ograniczeń.
 - 4.5.a. Wymiana punktu niedopuszczalnego ze względu na warunki (4.7) i (4.8) na jego naprawioną wersję z prawdopodobieństwem p_w .
 - 4.5.b. Ukazanie punktu niedopuszczalnego ze względu na ograniczenia (4.7) i (4.8) zależne od stopnia ich przekroczenia.
 5. Dla $k = 1$ do L_{pz} lub do momentu spełnienia warunku zatrzymania powtarzaj:
 - 5.1. Dla $l = 1$ do L_{pw} powtarzaj:
 - 5.1.1. Wyznaczenie punktu próbnego ch' poprzez zastosowanie operacji przesunięcia (mutacji i transpozycji) do punktu bieżącego ch .
 - 5.1.2. Ocena punktu próbnego ch' (zależna od sposobu postępowania z punktami niedopuszczalnymi) wg 4.1.a ÷ 4.5.b.
 - 5.1.3. Wyznaczenie różnicy kosztów $\Delta F_p = F_p(ch') - F_p(ch)$.
 Jeśli $\Delta F_p \geq 0$ – akceptacja punktu próbnego $ch = ch'$, w przeciwnym przypadku wyznaczenie prawdopodobieństwa akceptacji $p_a(\Delta F_p, T_k) = \exp(-\Delta F_p / T_k)$. Jeśli $r_r < p_a(\Delta F_p, T_k)$ akceptacja punktu próbnego: $ch = ch'$.
 - 5.2. Sprawdzenie warunku zatrzymania.
 - 5.3. Korekta temperatury.

Schemat blokowy algorytmu ERO-k za pomocą symulowanego wyżarzania przedstawiono na rys. 4.19.



Rys. 4.19. Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmów symulowanego wyżarzania – wersja kombinowana. Źródło: opracowanie własne.

4.4.3. ALGORYTM HYBRYDOWY SYMULOWANEGO WYŻARZANIA I ALGORYTMU EWOLUCYJNEGO

Proponuje się algorytm hybrydowy SW+AE łączący cechy algorytmu symulowanego wyżarzania i algorytmu ewolucyjnego. Algorytm SW+AE posiada strukturę algorytmu SW, tzn. pętlę zewnętrzną i wewnętrzną, przy czym równolegle zachodzi wiele procesów wyżarzania. Przestrzeń rozwiązań przeszukiwana jest przez populację punktów, które modyfikowane są niezależnie w pętli wewnętrznej algorytmu za pomocą operatora przesunięcia. Dobór temperatury startowej i sposób jej redukcji przebiega wg schematu Kirkpatricka zaprezentowanego w podrozdziale 4.4.2.1. W modelu można stosować takie same reprezentacje zmiennych jak w AE i SW, opisane w podrozdziale 4.4.1, oraz dostosowane do nich operatory przesunięcia (mutacji i transpozycji). Punkty niedopuszczalne podlegają naprawie lub karze zgodnie z algorytmami przedstawionymi w podrozdziale 4.4.1.1.3. Proponuje się kilka strategii postępowania z punktami zwróconymi przez

poszczególne procesy wyżarzania po zakończeniu cykli pętli wewnętrznej. Strategie te omówiono poniżej.

Strategia rekombinacji losowej SRL

Po wyznaczeniu nowej temperatury procesów zachodzi selekcja i rekombinacja punktów przez nie zwróconych. Stosuje się turniej binarny. Rekombinacja jest analogiczna do krzyżowania w AE; operatory krzyżowania omówiono w rozdz. 4.4.1. Po krzyżowaniu powstają nowe punkty, z których uruchamiane są procesy na kolejnym poziomie temperaturowym.

Strategia rekombinacji wg kryterium odległościowego SRO

W strategii tej stosuje się deterministyczne kryterium doboru punktów do rekombinacji – kryterium minimalnego dystansu (w metryce Hamminga lub Euklidesa) pomiędzy punktami zwróconymi przez procesy. Oznacza to, że krzyżowaniu podlegają pary punktów leżących blisko siebie w przestrzeni zadania. Selekcja punktów zachodzi bez powtórzeń. Selekcję odległościową zaprogramowano w funkcji SELEKCJA_ODL.m. Algorytm strategii SRO przedstawia się następująco:

1. Utwórz listę $L = (1, 2, \dots, L_{pop})$.
2. Dla $i = 1$ do $L_{pop}/2$ wykonaj:
 - 2.1. Przyjmij $l = L(i)$.
 - 2.2. Znajdź punkt w populacji zwróconej przez procesy wyżarzania, który leży najbliżej punktu l -tego; numer tego punktu znajduje się na j -tej pozycji listy L .
 - 2.3. Usuń elementy j -ty z listy L .
 - 2.4. Rekombinuj punkty l -ty i j -ty.

Strategia rekombinacji z najlepszym punktem SRN

W podejściu tym każdy punkt populacji zwróconej przez procesy wyżarzania rekombinuje z najlepszym punktem znalezionym do tej pory. Ponieważ licznosc populacji jest stała, tylko jeden zrekombinowany potomek jest do niej włączany, zastępując swego rodzica. Strategia ta zapewnia zachowanie materiału genetycznego najlepszego punktu i przeszukuje przestrzeń wokół niego.

Strategia mikrowyżarzania SMW

W strategii tej punkty zwrócone przez procesy wyżarzania zastępowane są najlepszym punktem znalezionym do tej pory. Oznacza to, że wszystkie procesy na kolejnym poziomie temperaturowym startują z tego samego punktu i przeszukują jego sąsiedztwo. W strategii SMW nie stosuje się rekombinacji. W dziedzinie algorytmów ewolucyjnych istnieje podejście zwane mikroalgorytmem genetycznym [Rut97]. Idea polega na przeszukiwaniu przestrzeni

rozwiązań za pomocą algorytmu genetycznego z niewielką populacją i liczbą generacji, który uruchamia się cyklicznie z populacji startowej złożonej z najlepszego osobnika znalezionej w poprzednich uruchomieniach oraz pozostałych osobników utworzonych losowo. Ponieważ losowo utworzone osobniki zapewniają w krótkich cyklach wystarczającą różnorodność puli genów, nie stosuje się mutacji. W mikrowyżarzaniu liczba generacji (równoznaczna z liczbą iteracji pętli wewnętrznej) również jest niewielka, ale nowy materiał genetyczny wprowadza się poprzez operację przesunięcia. Ponadto kolejne restarty algorytmu następują przy niższej temperaturze, co na gruncie AE oznacza zwiększenie naporu selekcyjnego. Ważne jest, aby operator przesunięcia umożliwiał przeskoki punktów poza obszary przyciągania minimów lokalnych, w których lokują się punkty bieżące.

Aby chronić najlepsze rozwiązanie w strategiach SRL, SRO i SRN stosuje się model elitarny: jeden z procesów uruchamia się zawsze z najlepszego znalezionej do tej pory punktu.

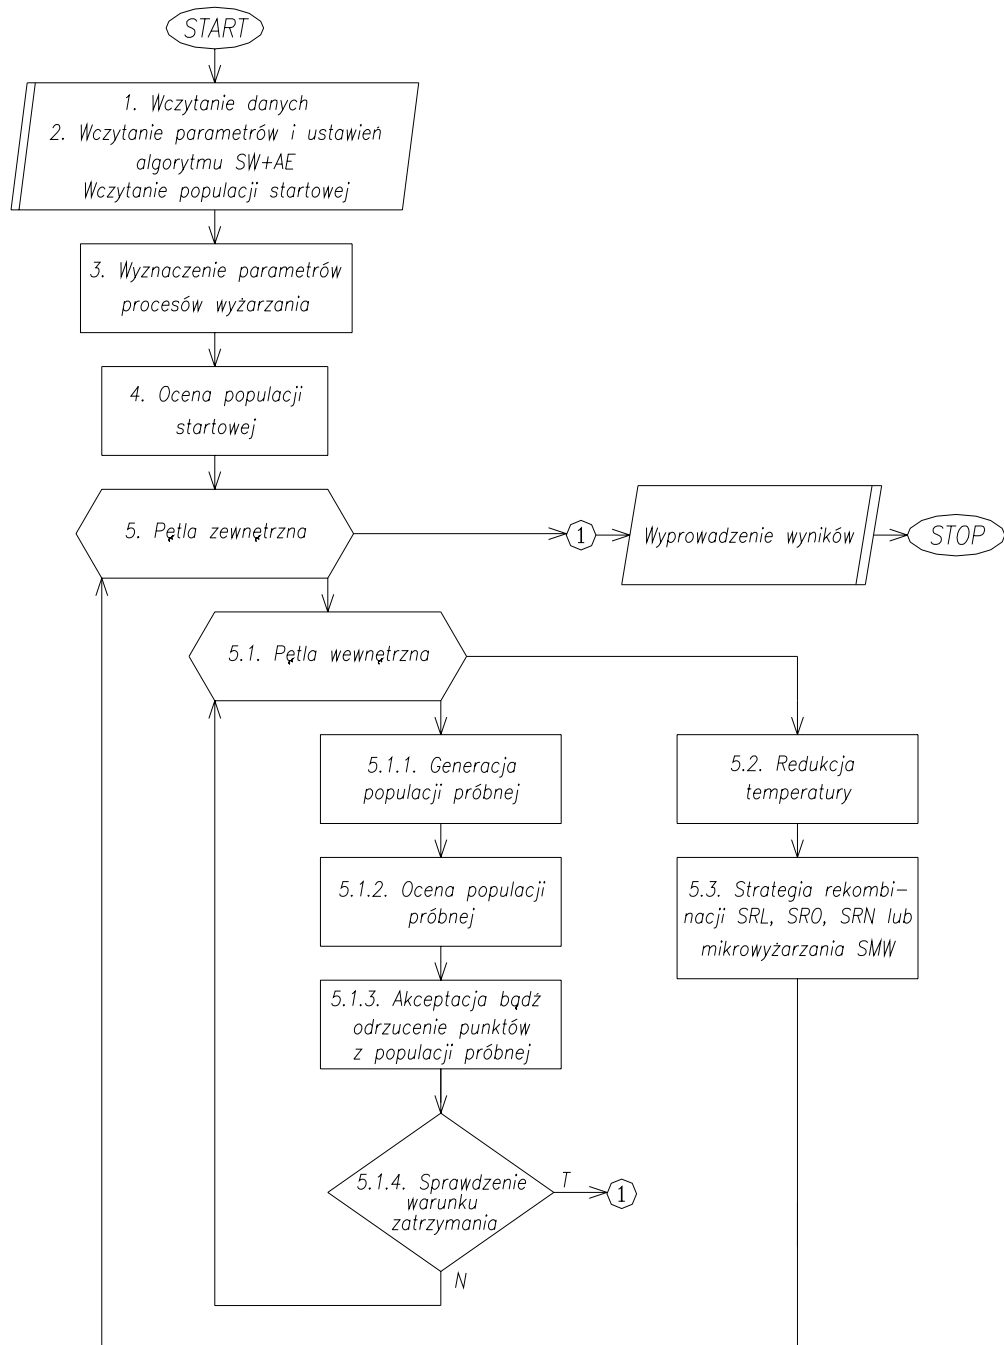
Schemat algorytmu optymalizacyjnego

Algorytm SW+AE w zastosowaniu do ERO-k na poziomie elektrowni zaprezentowano poniżej:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych generacji jednostek P_{nmini} i P_{nmaxi} , charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie t_{pmini} i minimalnych czasów pracy po rozruchu t_{rmini} .
2. Określenie parametrów i ustawień algorytmu SW+AE: wersji i parametrów schematu wyżarzania, liczby iteracji pętli zewnętrznej L_{pz} i wewnętrznej L_{pw} , liczebności populacji L_{pop} , sposobu reprezentacji zmiennych i parametrów kodowania, sposobu postępowania z osobnikami niedopuszczalnymi, populacji początkowej P_1 , metody i parametrów przesunięcia, wariantu strategii (rekombinacji lub mikrowyżarzania), metody i parametrów rekombinacji, parametrów zastępczych funkcji kosztu, warunku zatrzymania.
3. Wyznaczenie temperatury początkowej procesów wyżarzania T_1 oraz współczynnika redukcji temperatury r_T .
4. Ocena populacji początkowej P (zależna od sposobu postępowania z punktami niedopuszczalnymi; a – strategia naprawy, b – strategia karania):
 - 4.1.a. Naprawa punktów niedopuszczalnych ze względu na ograniczenia związane z zakresem generacji współpracujących jednostek (4.7) i (4.8).
 - 4.1.b. Wyznaczenie stopnia naruszenia ograniczeń (4.7) i (4.8).
 - 4.2.a. Ekonomiczny rozdział obciążeń dla naprawionych wersji punktów spełniających ograniczenia (4.9) i (4.10); wyznaczenie ich kosztów zmiennych.
 - 4.2.b. Ekonomiczny rozdział obciążeń dla punktów dopuszczalnych ze względu na ograniczenia (4.7) ÷ (4.10); wyznaczenie ich kosztów zmiennych.

- 4.3.a. Wyznaczenie kosztów rozruchów dla punktów dopuszczalnych ze względu na ograniczenia związane z minimalnym czasem postoju (4.9) i pracy (4.10) lub wyznaczenie stopnia naruszenia tych ograniczeń w przypadku punktów, które je naruszają.
- 4.3.b. Wyznaczenie kosztów rozruchów dla punktów dopuszczalnych ze względu na warunki (4.7) ÷ (4.10) lub wyznaczenie stopni naruszenia ograniczeń (4.9) i (4.10) w przypadku punktów spełniających warunki (4.7) i (4.8), a naruszających warunek (4.9) lub (4.10).
- 4.4.a.b. Ukazanie punktów niedopuszczalnych ze względu na ograniczenia (4.9) i (4.10) zależne od stopnia przekroczenia tych ograniczeń.
- 4.5.a. Wymiana punktów niedopuszczalnych ze względu na warunki (4.7) i (4.8) na ich naprawione wersje z prawdopodobieństwem p_w .
- 4.5.b. Ukazanie punktów niedopuszczalnych ze względu na ograniczenia (4.7) i (4.8) zależne od stopnia ich przekroczenia.
5. Dla $k = 1$ do L_{pz} powtarzaj:
 - 5.1. Dla $l = 1$ do L_{pw} lub do momentu spełnienia warunku zatrzymania powtarzaj:
 - 5.1.1. Wyznaczenie populacji punktów próbnych P' poprzez zastosowanie operacji przesunięcia (mutacji i transpozycji) do punktów z populacji bieżącej P .
 - 5.1.2. Ocena populacji próbnej P' (zależna od sposobu postępowania z punktami niedopuszczalnymi) wg 4.1.a ÷ 4.5.b.
 - 5.1.3. Powtarzaj dla $i = 1$ do L_{pop} :
 - 5.1.3.1. Wyznaczenie różnicy kosztów $\Delta F_{Pi} = F_P(ch_i') - F_P(ch_i)$.
 Jeśli $\Delta F_{Pi} \geq 0$ – akceptacja punktu próbnego $ch_i = ch_i'$, w przeciwnym przypadku wyznaczenie prawdopodobieństwa akceptacji $p_{ai}(\Delta F_{Pi}, T_{ki}) = \exp(-\Delta F_{Pi} / T_{ki})$. Jeśli $r_{ri} < p_{ai}(\Delta F_{Pi}, T_{ki})$ akceptacja punktu próbnego $ch_i = ch_i'$.
 - 5.1.4. Sprawdzenie warunku zatrzymania.
 - 5.2. Korekta temperatury.
 - 5.3. Strategia rekombinacji SRL, SRO, SRN lub mikrowyżarzania SMW.

Schemat blokowy tego algorytmu przedstawiono na rys. 4.20.



Rys. 4.20. Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmu hybrydowego SW+AE – wersja kombinowana. Źródło: opracowanie własne.

4.4.4. OBLICZENIA OPTIMALIZACYJNE EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ NA POZIOMIE ELEKTROWNI – PODEJŚCIE KOMBINOWANE

Ekspertyzacje numeryczne przeprowadzono w następującym porządku:

1. obliczenia pomocnicze mające na celu dobór ustawień i parametrów algorytmu ewolucyjnego,
2. obliczenia pomocnicze mające na celu dobór ustawień i parametrów algorytmu symulowanego wyżarzania,
3. rozwiązanie zadania ERO-k dla elektrowni, zdefiniowanego w podrozdziale 4.1, z wykorzystaniem algorytmów: ewolucyjnych, SW, SW+AE oraz, dla porównania, algorytmów: z twarzą selekcją, Monte Carlo i charakterystyk czasów granicznych.

W celu określenia najkorzystniejszych ustawień i parametrów AE i SW przeprowadzono obliczenia optymalizacyjne dla zadania zdefiniowanego w podrozdziale 4.1, ale dla liczby jednostek $N = 3$ (bloki nr 1, 2 i 3), przebiegu zapotrzebowania $P'_z(t) = P_z(t)/4$, ($t = 1, 2, \dots, 24$), poziomu rezerwy $P'_{rw}(t) = 0,05P'_{z,max}$ i stanu początkowego $t_{ps} = [-24, -24, -24]$. Okrojenie zadania do trzech jednostek wytwórczych na etapie poszukiwań najlepszego algorytmu było konieczne ze względu na relatywnie długi czas działania algorytmów i dużą liczbę przypadków, które należy przeliczyć. Optymalne rozwiązanie zadania uproszczonego, znalezione przez opracowane algorytmy i sprawdzone metodą przeglądu zupełnego¹, przedstawiono w tablicy D6.1 zamieszczonej w dodatku 6.

Po wytypowaniu najlepszych ustawień i parametrów algorytmów optymalizacyjnych przeprowadzono obliczenia ERO-k dla zadania pełnego (12 jednostek wytwórczych), określonego w podrozdziale 4.1.

Ponieważ algorytm SW+AE jest hybrydą AE i SW należy się spodziewać, że operatory dające najlepsze rezultaty w AE i SW okażą się najefektywniejsze także w algorytmie hybrydowym. Z tego powodu zrezygnowano z czasochłonnych obliczeń optymalizacyjnych uproszczonego zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmu SW+AE, a w zadaniu pełnym stosowano operatory wykazujące najlepsze działanie w uproszczonym zadaniu ERO-k rozwiązany za pomocą AE i SW.

Obliczenia przeprowadzono w programie Matlab 6.1 firmy MathWorks pracującym w systemie Windows 98, z wykorzystaniem oryginalnych programów napisanych przez autora rozprawy zamieszczonych w dodatku 8, na komputerze klasy PC z procesorem Pentium III 800 MHz i pamięcią operacyjną SDRAM 256 MB.

¹ Patrz str. 159 i 160.

Dobór ustawień i parametrów algorytmów ewolucyjnych

Do oceny działania AE w uproszczonym zadaniu ERO-k stosowano następujące wskaźniki:

- częstość znalezienia przez AE optymalnego rozwiązania okrojonego zadania ERO-k – c_{opt} , wyznaczana dla zadanej liczby generacji $L_{gen} = 200$ i liczebności populacji $L_{pop} = 50$;
- średnią liczbę odwołań do funkcji kosztu F_P potrzebną do znalezienia rozwiązania optymalnego – l_{opt} i jej odchylenie standardowe $\sigma_{l_{opt}}$;
- średni czas wymagany do znalezienia rozwiązania optymalnego – t_{opt} .

Powyższe wskaźniki jakości działania AE wyznaczono eksperymentalnie na podstawie 30 uruchomień algorytmu. W pierwszej fazie badano AE z reprezentacją binarną stanów pracy jednostek RB1, z algorytmem naprawy osobników niedopuszczalnych i różnymi operatorami mutacji: MBR – warianty AE1 ÷ AE7 w tablicy D6.2 (dodatek 6), MB1 – warianty AE8 ÷ AE14, MB2 – warianty AE15 ÷ AE21, MB3 – warianty AE22 ÷ AE28. Stosowano krzyżowanie jednopunktowe, losowy lub deterministyczny algorytm naprawy oraz operator transpozycji. Dla najlepszego wariantu AE wykonano eksperymenty z krzyżowaniem wielopunktowym i jednorodnym (AE29 ÷ AE33). Dalej, dla tej reprezentacji, stosowano strategię z funkcją kary (z $f_d(t)$ określoną wzorem (4.96b)) i różnymi operatorami genetycznymi (AE34 ÷ AE43). W drugiej fazie badano AE z reprezentacją binarną momentów załączeń i odstawień RB2, z różnymi operatorami krzyżowania oraz z operatorem mutacji i transpozycji (AE44 ÷ AE52). Podobne eksperymenty wykonano dla reprezentacji całkowitoliczbowej momentów załączeń i odstawień RC (AE53 ÷ AE66). W każdym wariantcie AE stosowano jednakowe, utworzone w sposób losowy populacje startowe (w każdym uruchomieniu inne).

Następujące parametry AE używanych w eksperymentach przyjęto jako stałe:

- liczbę generacji – $L_{gen} = 200$,
- liczebność populacji – $L_{pop} = 50$,
- prawdopodobieństwo krzyżowania – $p_k = 0,9$,
- rozmiar turnieju w selekcji turniejowej – $r_t = 2$,
- parametry mutacji MB3 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$,
- szacowaną wartość minimum funkcji kosztu – $\widehat{F}_{P_{min}} = 717\,000$ zł.

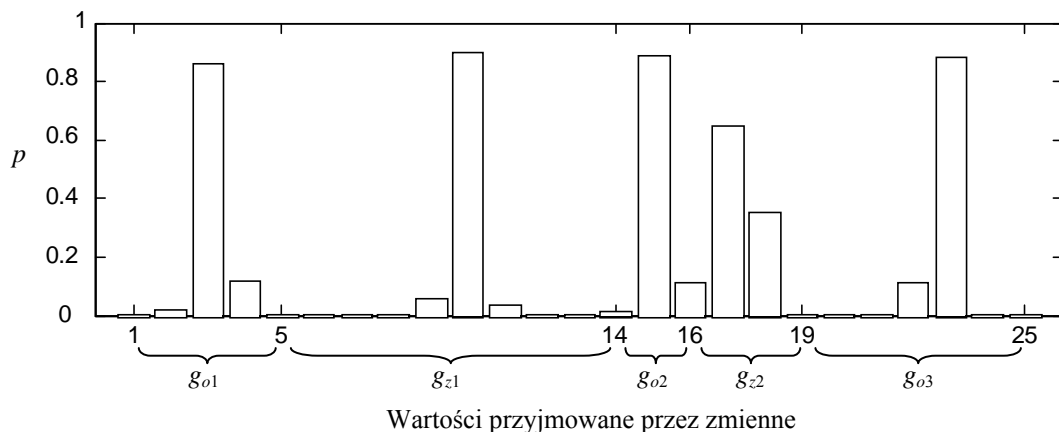
Parametry te dobrano po wcześniejszym wykonaniu obliczeń pomocniczych.

W tablicy D6.2 zamieszczonej w dodatku 6 zestawiono rezultaty eksperymentów, a wnioski z nich wypływające wypunktowano poniżej:

1. Najlepszy wynik osiągnięto dla AE z reprezentacją binarną stanów pracy jednostek RB1, mutacją binarną MB3, krzyżowaniem jednopunktowym, strategią naprawy osobników niedopuszczalnych w wersji deterministycznej i prawdopodobieństwem wymiany $p_w = 1$ oraz z operatorem transpozycji (wariant AE25 zaznaczony w tablicy D6.2 wytłuszczonym drukiem). Algorytm w tym wariantcie potrzebował średnio sześciu

generacji populacji złożonych z 50-ciu osobników i 13 s do znalezienia optymalnego rozwiązania.

2. Dla reprezentacji RB1 operator krzyżowania jednopunktowego był najlepszym operatorem rekombinacji. Operatory krzyżowania wielopunktowego i jednorodnego wykazywały nieznacznie gorsze działanie.
3. Dla reprezentacji RB2 i RC operatory krzyżowania K1P, KWP i KJR dawały podobne wyniki. Krzyżowanie arytmetyczne w reprezentacji całkowitoliczbowej wykazywało słabe działanie. Wynika to ze specyfiki samego operatora, który tworzy potomków poprzez kombinacje liniowe rodziców, stąd prawdopodobieństwo przyjmowania przez zmienne wartości w okolicach środka przedziału ich zmienności jest znacznie większe od prawdopodobieństwa przyjmowania przez nie wartości granicznych. W rozwiązaniu optymalnym wszystkie zmienne poza jedną przyjmują wartości graniczne. Na rys. 4.21 pokazano wyznaczone eksperymentalnie prawdopodobieństwa p przyjęcia przez zmienne poszczególnych wartości całkowitych w okrojonym zadaniu ERO-k, po dwustu generacjach populacji 50-cio elementowej przetwarzanej wyłącznie za pomocą operatora krzyżowania arytmetycznego. Podobnie słabo działał operator krzyżowania heurystycznego.



Rys. 4.21. Prawdopodobieństwa p przyjęcia przez zmienne w zadaniu ERO-k wartości z ich dziedzin po zastosowaniu wielokrotnej operacji krzyżowania arytmetycznego. Źródło: opracowanie własne.

4. Naprawa osobników niedopuszczalnych w AE z reprezentacją RB1 pozwalała uzyskać lepsze wyniki od strategii z funkcją kary, niezależnie od sposobu reprezentacji zmiennych. Prawdopodobieństwo wymiany równe 1 dawało na ogół lepsze efekty niż wymiana 5% niedopuszczalnych osobników. Deterministyczna strategia naprawy wykazywała działanie lepsze od losowej. W strategii SFK algorytm miał trudniejsze zadanie: przestrzeń rozwiązań niedopuszczalnych jest większa, stąd wynika większa liczba generacji niezbędnych do znalezienia rozwiązania dopuszczalnego i optimum.
5. W AE z reprezentacją RB1 zdecydowanie najlepiej działał operator mutacji RB3. W 660 eksperymentach z udziałem tego operatora rozwiązanie optymalne znaleziono 638 razy. Operatory MBR i MB1 działały wyraźnie słabiej. W AE z reprezentacją RC i operatorami

krzyżowania arytmetycznego i heurystycznego lepiej działał operator mutacji równomiernej MCR.

6. Operacja transpozycji na ogół znacznie zwiększała efektywność AE. Operator ten pozwalał uniknąć pułapki minimum lokalnego przesuując rozwiązanie z jednego minimum do innego.

Dobór ustawień i parametrów algorytmów symulowanego wyżarzania

Do oceny różnych wariantów algorytmu SW w uproszczonym zadaniu ERO-k stosowano wskaźniki takie, jak dla AE, przy czym częstość znalezienia optimum c_{opt} wyznaczano dla $L_{pz}L_{pw} = L_{gen}L_{pop} = 10\ 000$. Każdy wariant algorytmu SW uruchamiano 30-krotnie, z jednakowych, generowanych losowo punktów startowych (w każdym uruchomieniu innych).

W pierwszej fazie badano SW z reprezentacją RB1, z algorytmem naprawy rozwiązań niedopuszczalnych i różnymi operatorami przesunięcia. Stosowano schemat wyżarzania Kirkpatricka (SK) lub Aartsa (SA), losowy lub deterministyczny algorytm naprawy (warianty SW1 ÷ SW11 w tablicy D6.3). Dalej, dla tej reprezentacji, wykonano eksperymenty ze strategią kary, operatorem przesunięcia MB3+OT i różnymi schematami wyżarzania (SW12 i SW13). W drugiej fazie badano SW z reprezentacją RB2, schematem Kirkpatricka i Aartsa (SW14 ÷ SW15). W fazie trzeciej stosowano reprezentację RC (SW16 ÷ SW18).

W przeprowadzonych eksperymentach stosowano następujące stałe parametry algorytmu SW:

- liczbę iteracji pętli zewnętrznej – $L_{pz} = 200$,
- liczbę iteracji pętli wewnętrznej – $L_{pw} = 50$,
- oczekiwaną liczbę mutacji punktu – $w_m = 1$,
- oczekiwaną liczbę transpozycji punktu – $w_t = 0,25$,
- parametry mutacji MB3 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$,
- szacowaną wartość minimum funkcji kosztu – $\widehat{F}_{P_{min}} = 717\ 000$ zł,
- prawdopodobieństwo wymiany w strategii naprawy – $p_w = 1$.

Wyniki symulacji zamieszczono w tablicy D6.3 (dodatek 6). Z eksperymentów wypływają następujące wnioski:

1. Podobnie jak dla AE najlepszy wynik osiągnięto dla SW z reprezentacją binarną stanów pracy jednostek RB1, mutacją binarną MB3 i transpozycją w roli operatora przesunięcia oraz strategią naprawy osobników niedopuszczalnych w wersji deterministycznej (wariant SW10). Rezultaty otrzymane przez obydwa algorytmy są porównywalne, chociaż algorytm SW działał w tym przypadku ok. trzykrotnie wolniej.
2. Schemat Aartsa, w którym temperatura jest adaptacyjnie korygowana zależnie do efektywności przeszukiwania przestrzeni rozwiązań, wykazywał na ogół lepsze działanie od statycznego schematu Kirkpatricka. Wyjątkiem jest wariant algorytmu z reprezentacją binarną RB1 i RB2 oraz ze strategią kary SFK (warianty SW12, SW13, SW14 i SW15),

gdzie schemat Kirkpatricka pozwalał uzyskać większą częstość c_{opt} , lecz liczba odwołań do funkcji kosztu l_{opt} była tu ok. dwukrotnie większa niż w schemacie Aartsa.

3. Dla reprezentacji RB1, podobnie jak w AE, zdecydowanie słabiej działały operatory mutacji MBR i MB1 od bardziej inteligentnych operatorów MB2 i MB3, które zapewniały bliską jedności częstość trafienia w optimum.
4. Słabiej w stosunku do AE działał algorytm SW z reprezentacją RB2 i RC.
5. Porównanie wariantów SW11 oraz SW10 wskazuje na pozytywną rolę jaką pełni operator transpozycji w procesie wyżarzania.

4.4.4.1. WYNIKI

Obliczenia dla pełnego zadania ERO-k na poziomie elektrowni, określonego w podrozdziale 4.1, wykonano z wykorzystaniem algorytmów optymalizacyjnych, które wykazywały najlepsze działanie dla zadania uproszczonego, przy czym testowano wszystkie sposoby reprezentacji zmiennych oraz strategie postępowania z rozwiązaniami niedopuszczalnymi. W algorytmie SW+AE stosowano operatory, które działały najlepiej w AE i SW. Dla reprezentacji RB1 w algorytmie SW+AE testowano różne strategie rekombinacji: SRL, SRO, SRN oraz strategię mikrowyżarzania SMW. Dla pozostałych reprezentacji przyjęto tę strategię, która dała najlepszy wynik w reprezentacji RB1. Każdy algorytm uruchamiano 10-krotnie. We wszystkich wariantach algorytmów stosowano jednakowe, utworzone w sposób losowy populacje (punkty) startowe (w każdym uruchomieniu inne), a maksymalna liczba odwołań do funkcji kosztu w każdym przypadku wynosiła 100 000. Algorytmy kończyły działanie, jeśli 50 000 kolejnych odwołań do funkcji kosztu nie przynosiło poprawy rezultatu. W zastępczej funkcji kosztu (4.94) $f_d(t)$ liczono ze wzoru (4.96b).

Dla porównania wykonano obliczenia optymalizacyjne stosując algorytm losowy z twardą selekcją, metodę Monte Carlo oraz klasyczną metodę charakterystyk czasów granicznych. Przegląd zupełny nie wchodzi tutaj w rachubę, gdyż samo wygenerowanie rozwiązań dla wszystkich możliwych przypadków (w instrukcji iteracyjnej for) zajęłoby ponad $3 \cdot 10^{74}$ lat (generacja miliona ciągów binarnych trwa ok. 21 s). Przeliczenie wszystkich możliwych przypadków wymaga okrojenia zadania do np. dwóch JW i okresu T rzędu kilku godzin. W takim jednak przypadku obliczenia porównawcze z wykorzystaniem proponowanych modeli, z uwagi na specyfikę działania operatorów genetycznych (np. mutacje MB2 i MB3), które zostały skonstruowane dla okresu optymalizacji $T = 24$ h i dla $T < 24$ h mogą działać mniej efektywnie, nie byłoby miarodajne. Poza tym warunki dopuszczalnych czasów odstawień i pracy JW zawężyłyby wtedy przestrzeń rozwiązań dopuszczalnych (lub nawet by ją likwidowały), co zmieniałoby postać zadania.

Do oceny działania algorytmów stosowano następujące wskaźniki:

- minimalną (F_{Pmin}), maksymalną (F_{Pmax}) i średnią (\bar{F}_p) wartość kosztu najlepszych rozwiązań znalezionych przez algorytm w 10-ciu uruchomieniach oraz odchylenie standardowe kosztu tych rozwiązań σ_{F_p} ;

- częstość znalezienia przez algorytm rozwiązania¹ $P_{nopt} - c_{opt}$, wyznaczana na podstawie 10-ciu uruchomień, dla zadanej liczby generacji oraz liczebności populacji lub zadanej liczby iteracji pętli zewnętrznej i wewnętrznej;
- średnią liczbę odwołań do funkcji kosztu potrzebną do znalezienia rozwiązania $P_{nopt} - l_{opt}$;
- średni czas potrzebny do znalezienia rozwiązania $P_{nopt} - t_{opt}$.

Najlepsze rozwiązanie P_{nopt} , znalezione przez testowane algorytmy optymalizacyjne, zaprezentowano na rys. 4.23 oraz w tabelicy 4.11.

Algorytmy ewolucyjne

Przyjęto następujące stałe parametry AE:

- liczbę generacji – $L_{gen} = 1000$,
- liczebność populacji – $L_{pop} = 100$,
- prawdopodobieństwo krzyżowania – $p_k = 0,9$,
- oczekiwaną liczbę mutacji chromosomu – $w_m = 0,5$,
- oczekiwaną liczbę transpozycji chromosomu – $w_t = 0,25$,
- prawdopodobieństwo wymiany osobników niedopuszczalnych w strategii naprawy – $p_w = 1$,
- rozmiar turnieju w selekcji turniejowej – $r_t = 2$,
- parametry mutacji MB3 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$,
- szacowaną wartość minimum funkcji kosztu – $\hat{F}_{Pmin} = 2,58 \cdot 10^6$ zł.

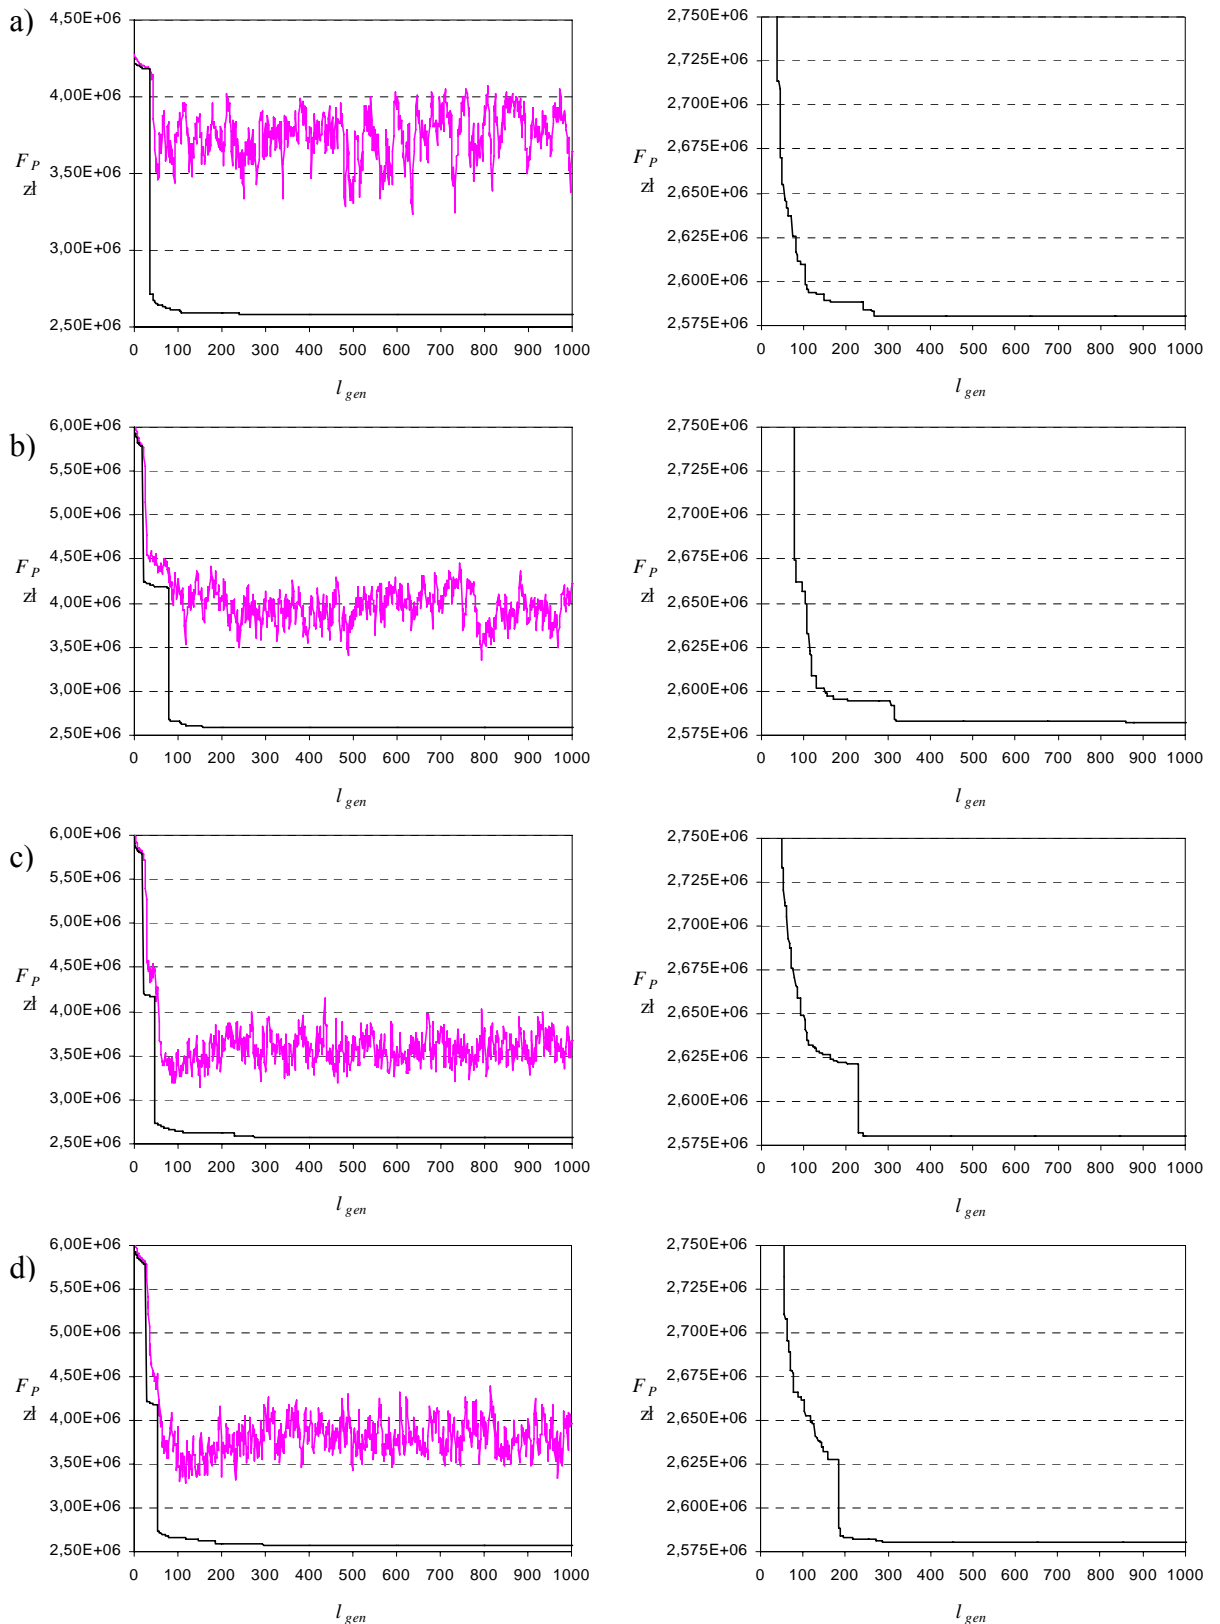
W tabelicy 4.10 zestawiono wyniki obliczeń optymalizacyjnych.

Tablica 4.10. Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów ewolucyjnych. Źródło: oprac. własne.

Wariant AE	Ustawienia	F_{Pmin} zł	F_{Pmax} zł	\bar{F}_P zł	σ_{F_P} zł	c_{opt}	l_{opt}	t_{opt} h
1.	RB1+MB3+K1P+SND+OT	2 579 803	2 584 918	2 581 059	1524	0,2	70 650	2,25
2.	RB1+MB3+K1P+SFK+OT	2 579 803	2 582 797	2 580 780	989	0,2	72 050	1,44
3.	RB2+MBR+K1P+SFK+OT	2 579 803	2 580 261	2 580 051	228	0,4	33 800	0,78
4.	RC+MCN+K1P+SFK+OT	2 579 803	2 580 261	2 580 169	193	0,2	36 550	0,84

Na rys. 4.22 pokazano przebiegi procesów ewolucyjnych dla poszczególnych wariantów AE – średnią wartość funkcji kosztu populacji oraz koszt najlepszego chromosomu w kolejnych generacjach. Na wykresach z prawej strony zamieszczono szczegółowe przebiegi procesów na trzecim poziomie kosztowym.

¹ Rozwiązanie P_{nopt} jest najlepszym rozwiązaniem znalezionym przez testowane algorytmy; rozwiązanie optymalne jest nieznane.




Rys. 4.22. Średnia wartość funkcji kosztu populacji (wykres górny) oraz koszt najlepszego osobnika (wykres dolny) w kolejnych generacjach AE: a) wariant AE1, b) wariant AE2, c) wariant AE3, d) wariant AE4. Źródło: opracowanie własne.

Na rys. 4.23 pokazano harmonogramy pracy JW, a w tabelicy 4.11 obciążenia JW minimalizujące funkcję kosztu (4.2), przy ograniczeniach (4.5) ÷ (4.10). Całkowity dobowy koszt wytwarzania w tym przypadku wynosi $K_c = 2\,579\,803$ zł, w tym koszt zmienny – $K_z = 2\,495\,839$ zł i koszt rozruchów – $K_r = 83\,964$ zł.

Tablica 4.11. Najlepsze rozwiązanie zadania ERO-k dla elektrowni P_{nopt} , znalezione przez proponowane modele optymalizacyjne. Źródło: opracowanie własne.

Koszt całkowity: $K_c = 2\,579\,803$ zł, koszt zmienny $K_z = 2\,495\,839$ zł, koszt rozruchów $K_r = 83\,964$ zł.

Godz.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
P_{n1} , MW	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
P_{n2} , MW	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	281,05	284,45	260,02	255,55	235,03	195,52	180,00	180,00
P_{n3} , MW	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	238,06	239,40	227,70	255,51	269,32	269,32	206,60	231,54	288,69	292,07	267,77	263,33	242,92	203,62	180,00	180,00
P_{n4} , MW	180,00	180,00	180,00	180,00	180,00	180,00	180,00	234,78	229,96	231,25	219,96	246,80	260,12	260,12	199,60	223,66	278,81	282,07	258,63	254,34	234,64	196,73	180,00	180,00
P_{n5} , MW	180,00	180,00	180,00	180,00	180,00	180,00	180,00	292,61	287,03	288,53	275,45	306,53	321,96	321,96	251,88	279,74	343,60	347,38	320,23	315,26	292,46	248,55	190,18	180,00
P_{n6} , MW	180,00	180,00	180,00	180,00	180,00	180,00	180,00	267,92	262,78	264,16	252,14	280,72	294,91	294,91	230,46	256,08	314,81	318,28	293,31	288,75	267,78	227,40	180,00	180,00
P_{n7} , MW	180,00	180,00	180,00	180,00	180,00	180,00	180,00	259,69	254,18	255,66	242,75	273,44	288,68	288,68	219,47	246,98	310,05	313,78	286,97	282,06	259,54	216,18	180,00	180,00
P_{n8} , MW	282,01	253,57	254,57	243,51	247,78	263,63	282,69	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	314,16	251,05
P_{n9} , MW	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	261,97	238,07	233,70	213,63	180,00	0,00	0,00
P_{n10} , MW	350,00	323,91	324,94	313,60	317,98	334,22	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00
P_{n11} , MW	290,27	262,49	263,47	252,66	256,84	272,32	290,93	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	321,66	260,03
P_{n12} , MW	307,72	280,03	281,01	270,24	274,40	289,83	308,38	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	350,00	339,00	277,58



Rys. 4.23. Najlepsze harmonogramy pracy jednostek wytwórczych. Źródło: oprac. własne.

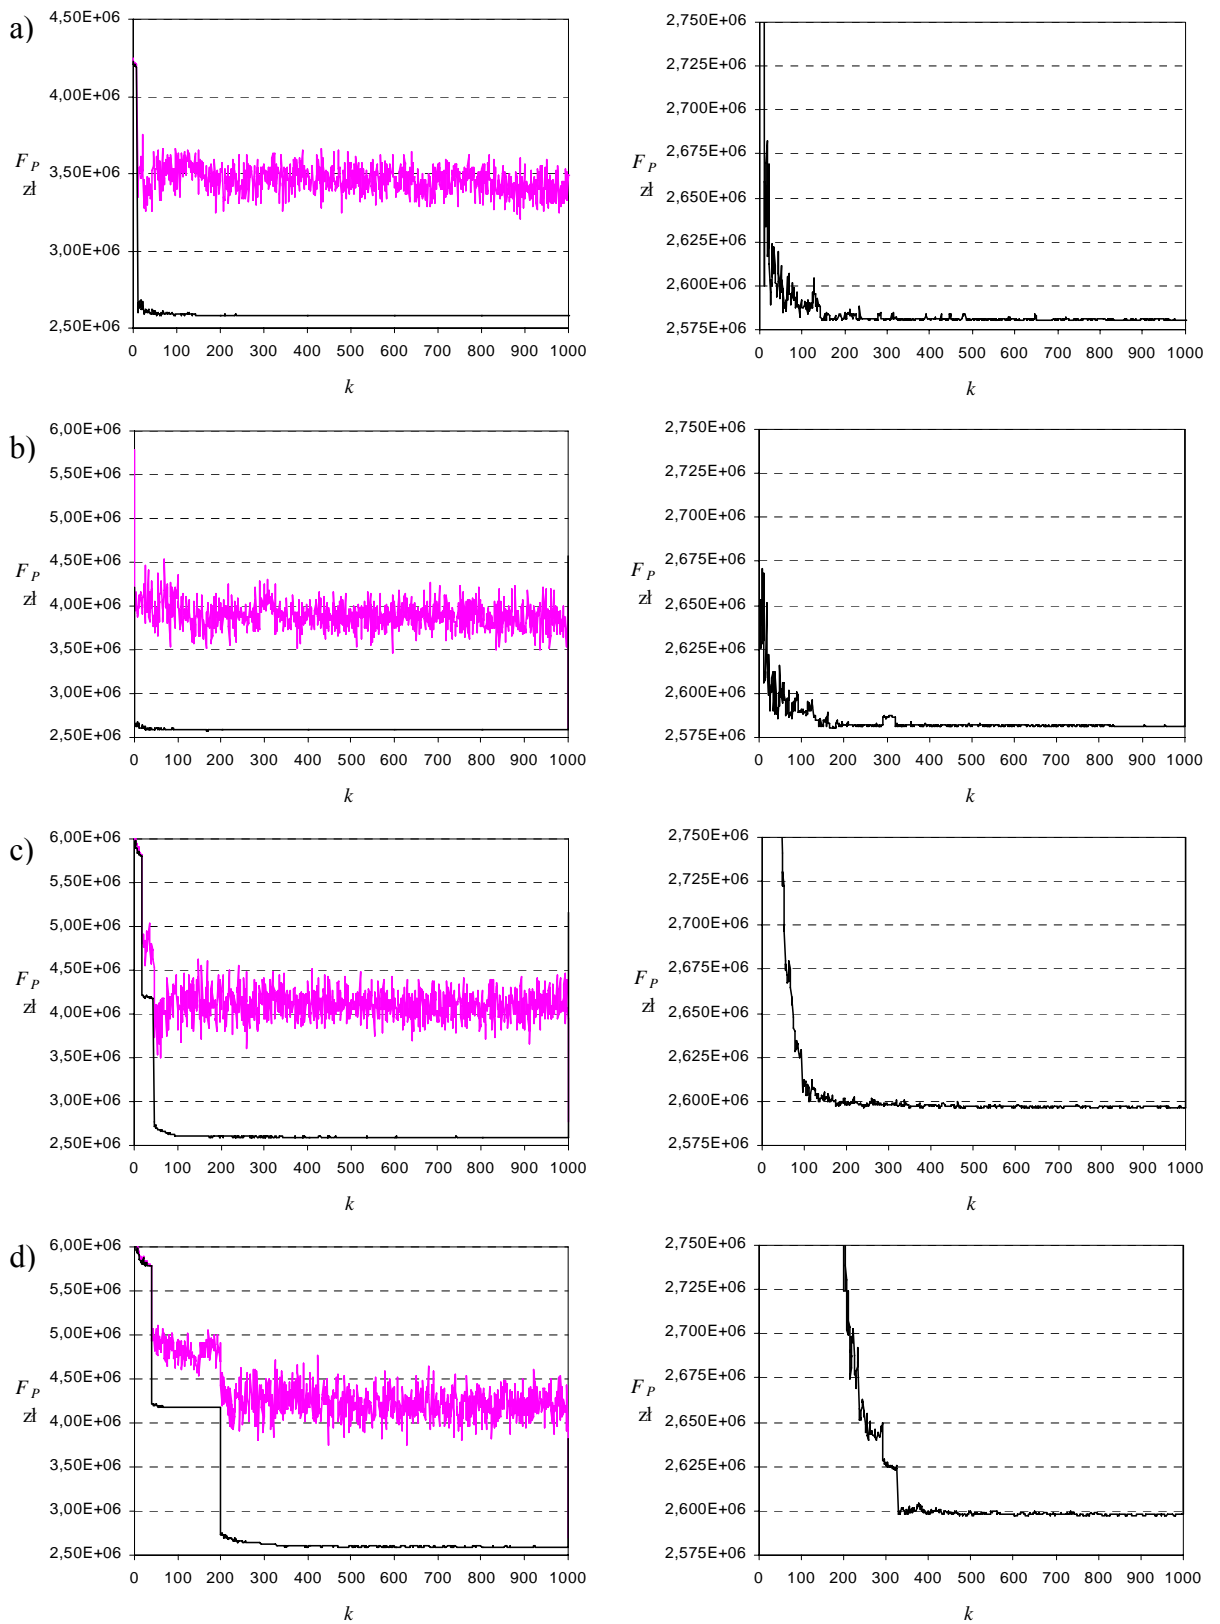
Algorytmy symulowanego wyżarzania

Stałe parametry algorytmów SW:

- liczba iteracji pętli zewnętrznej – $L_{pz} = 1000$,
- liczba iteracji pętli wewnętrznej – $L_{pw} = 100$,
- oczekiwana liczba mutacji punktu – $w_m = 1$,
- oczekiwana liczba transpozycji punktu – $w_t = 0,25$,
- prawdopodobieństwo wymiany osobników niedopuszczalnych w strategii naprawy – $p_w = 1$,
- parametry mutacji MB3 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$,
- szacowana wartość minimum funkcji kosztu – $\hat{F}_{P_{\min}} = 2,58 \cdot 10^6$ zł.

Tablica 4.12. Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów symulowanego wyżarzania. Źródło: opracowanie własne.

Wariant SW	Ustawienia	$F_{P_{\min}}$ zł	$F_{P_{\max}}$ zł	\bar{F}_P zł	σ_{F_P} zł	C_{opt}	l_{opt}	t_{opt} h
1.	RB1+SA+MB3+SND+OT	2 579 803	2 580 325	2 580 064	243	0,4	64 215	2,89
2.	RB1+SA+MB3+SFK+OT	2 579 803	2 581 375	2 580 463	721	0,5	57 637	2,41
3.	RB2+SA+MBR+SFK+OT	2 596 351	2 622 671	2 599 027	8 308	0,0	-	-
4.	RC+SA+MCN+SFK+OT	2 585 051	2 639 157	2 602 802	19 609	0,0	-	-



Rys. 4.24. Średnia wartość funkcji kosztu punktów próbnych (wykres górny) oraz koszt najlepszego punktu próbego (wykres dolny) na kolejnych poziomach temperaturowych SW: a) wariant SW1, b) wariant SW2, c) wariant SW3, d) wariant SW4. Źródło: oprac. własne.

Na rys. 4.24 zamieszczono przebiegi procesów wyżarzania – średnie wartości kosztu punktów próbnych oraz koszty najlepszych punktów bieżących na kolejnych poziomach temperaturowych k .

Algorytmy hybrydowe SW+AE

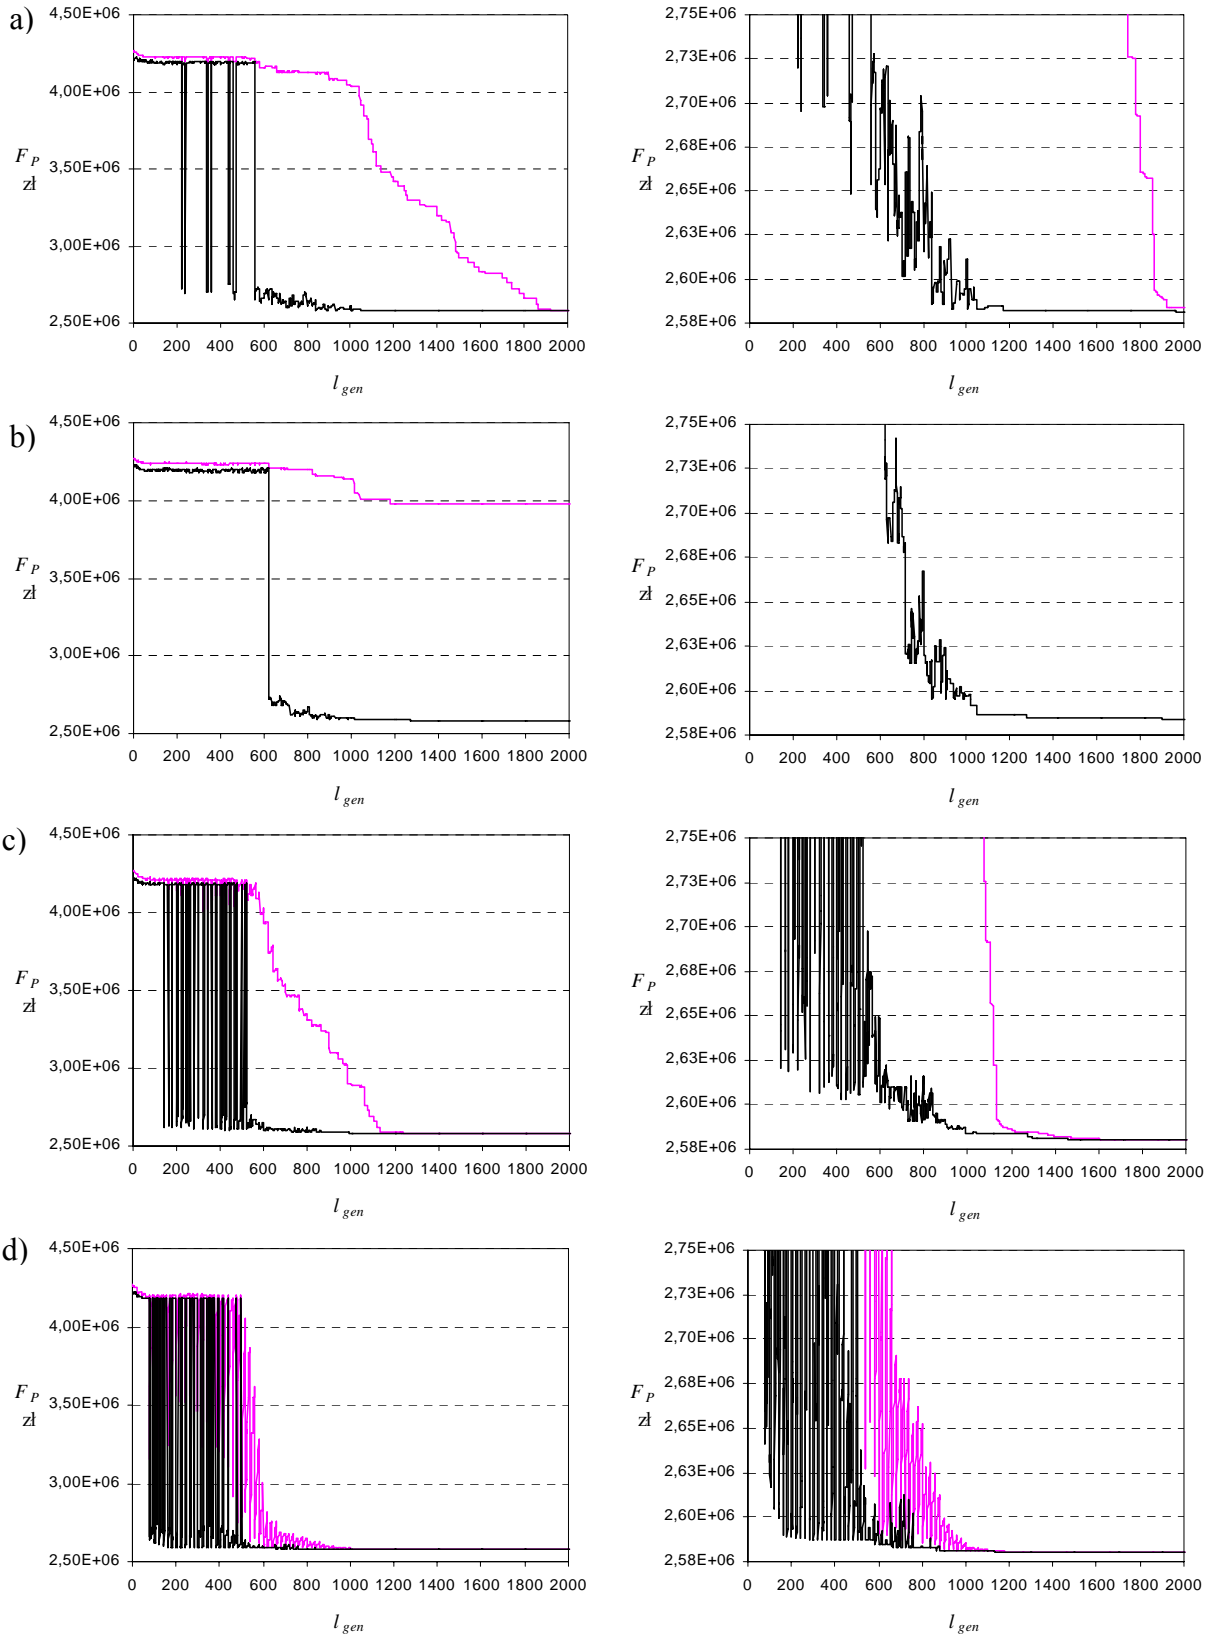
Przyjęto następujące stałe parametry algorytmu SW+AE:

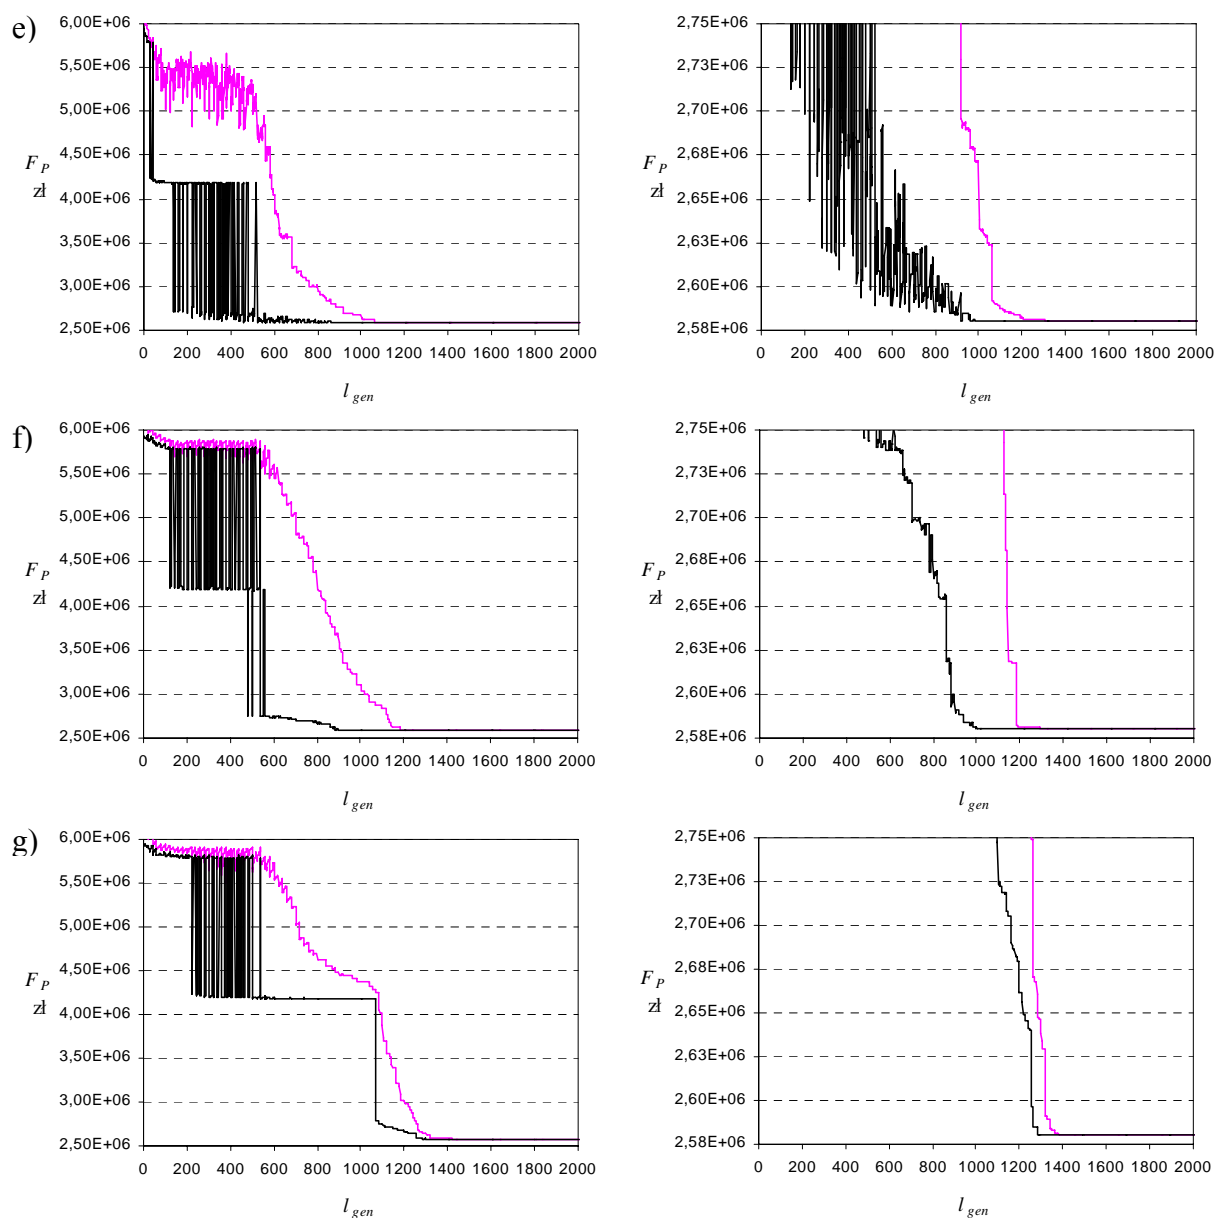
- liczbę iteracji pętli zewnętrznej – $L_{pz} = 100$,
- liczbę iteracji pętli wewnętrznej – $L_{pw} = 20$,
- liczebność populacji – $L_{pop} = 50$,
- oczekiwaną liczbę mutacji punktu – $w_m = 1$,
- oczekiwaną liczbę transpozycji punktu – $w_t = 0,25$,
- prawdopodobieństwo krzyżowania – $p_k = 0,9$,
- prawdopodobieństwo wymiany osobników niedopuszczalnych w strategii naprawy – $p_w = 1$,
- parametry mutacji MB3 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$,
- szacowaną wartość minimum funkcji kosztu – $\hat{F}_{P_{\min}} = 2,58 \cdot 10^6$ zł.

Tablica 4.13. Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów SW+AE. Źródło: opracowanie własne.

Wariant SW+AE	Ustawienia	$F_{P_{\min}}$ zł	$F_{P_{\max}}$ zł	\bar{F}_P zł	σ_{F_P} zł	C_{opt}	l_{opt}	t_{opt} h
1.	RB1+MB3+K1P+SND+OT+SRL	2 580 261	2 585 919	2 581 865	1 953	0,0	-	-
2.	RB1+MB3+K1P+SND+OT+SRO	2 581 754	2 589 205	2 585 067	2 578	0,0	-	-
3.	RB1+MB3+K1P+SND+OT+SRN	2 579 803	2 580 325	2 580 103	201	0,2	57 925	1,58
4.	RB1+MB3+K1P+SND+OT+SMW	2 579 803	2 581 759	2 580 365	673	0,3	62 411	1,40
5.	RB1+MB3+K1P+SFK+OT+SRN	2 580 261	2 581 759	2 580 436	466	0,0	-	-
6.	RB2+MBR+K1P+SFK+OT+SRN	2 579 803	2 629 673	2 595 212	20 969	0,1	58 050	0,56
7.	RC+MCR+K1P+SFK+OT+SRN	2 579 803	2 627 326	2 586 301	14 627	0,1	69 100	0,72

Na rys. 4.25 przedstawiono przebiegi algorytmu SW+AE – średnią wartość funkcji kosztu populacji bieżącej oraz koszt najlepszego punktu w kolejnych generacjach.





Rys. 4.25. Średnia wartość funkcji kosztu populacji bieżącej (wykres górny) oraz koszt najlepszego punktu (wykres dolny) w kolejnych generacjach algorytmu SW+AE: a) wariant SW+AE1, b) wariant SW+AE2, c) wariant SW+AE3, d) wariant SW+AE4, e) wariant SW+AE5, f) wariant SW+AE6, g) wariant SW+AE7. Źródło: opracowanie własne.

Algorytm z twardą selekcją


W podejściu tym generuje się punkty próbne poprzez modyfikację punktu bieżącego. Jeśli koszt punktu próbnego jest mniejszy od kosztu punktu bieżącego, przyjmuje się go za punkt bieżący. Algorytmy tego typu, wybierające za bazę poszukiwań najlepsze rozwiązanie znalezione dotychczas, noszą nazwę algorytmów z twardą selekcją [Gal90]. Przyjęto reprezentację binarną RB1 parametrów zadania. Punkt startowy generuje się losowo. Do oceny punktów próbkujących przestrzeni rozwiązań, które nie spełniają ograniczeń stosuje się

wzory (4.88) i (4.94) (strategia kary). Modyfikacje punktu bieżącego polegają na zmianie wartości losowo wybranego bitu, analogicznie jak w mutacji binarnej równomiernej.

Algorytm z twardą selekcją przebiega według następujących kroków:

1. Wczytanie danych (patrz p. 1 algorytmu zaprezentowanego w podrozdziale 4.4.2.2), generacja punktu startowego.
2. Ocena punktu startowego wg pp. 4.1.b ÷ 4.5.b algorytmu z podrozdziału 4.4.2.2.
3. Dla $k = 1$ do L_p powtarzaj:
 - 3.1. Wyznaczenie punktu próbnego ch' poprzez modyfikację punktu bieżącego ch .
 - 3.2. Ocena punktu próbnego wg pp. 4.1.b ÷ 4.5.b algorytmu z podrozdziału 4.4.2.2.
 - 3.3. Wyznaczenie różnicy kosztów $\Delta F_p = F_p(ch') - F_p(ch)$. Jeśli $\Delta F_p \geq 0$ – akceptacja punktu próbnego: $ch = ch'$.

Liczbę iteracji L_p ustalono na 100 000. W dziesięciu próbach algorytm z twardą selekcją zawsze znajdował rozwiązanie dopuszczalne. Otrzymano następujące wyniki: $F_{P_{\min}} = 2\,769\,269$ zł, $F_{P_{\max}} = 2\,867\,751$ zł, $\bar{F}_p = 2\,818\,197$ zł. Najlepsze znalezione przez ten algorytm rozwiązanie było gorsze o $\Delta F_{P_{\min}\%} = 7,34\%$ od rozwiązania P_{nopt} . Koszt punktu bieżącego w kolejnych iteracjach algorytmu pokazano na rys. 4.26.



Rys. 4.26. Koszt punktu bieżącego w kolejnych iteracjach i algorytmu z twardą selekcją.
Źródło: opracowanie własne.

Algorytm Monte Carlo

W tej metodzie losuje się z rozkładem jednostajnym punkty z przestrzeni rozwiązań, zapamiętując najlepsze rozwiązanie. Zastosowano binarną reprezentację stanów pracy jednostek RB1. Punkty niedopuszczalne oceniano za pomocą wzorów (4.88) i (4.94). Wykonano 10 eksperymentów, w których losowano 100 000 punktów. Wszystkie rozwiązania znajdowały się na pierwszym poziomie kosztowym (były niedopuszczalne ze względu na warunki (4.7) lub (4.8)).

Algorytm charakterystyk czasów granicznych

Algorytm charakterystyk czasów granicznych bazuje na kryteriach korzyści z odstawienia (2.17) lub uruchomienia bloku (2.18), opisanych szerzej w podrozdziale 2.3.

Dla każdej godziny $t = 1, 2, \dots, T$ rozważa się odstawienie lub uruchomienie każdej jednostki zależnie od jej stanu wyjściowego. Stany wyjściowe jednostek w godzinie $t = 1$ wynikają ze stanów początkowych t_{psi} (patrz tablica 4.1), a stany wyjściowe w każdej godzinie $t > 1$ są takie same, jak stany optymalne (względem kryteriów (2.17) lub (2.18)) w godzinie poprzedzającej ($t - 1$). Dla każdej jednostki i_z , o stanie wyjściowym „załączona” w chwili t , przy spełnionych warunkach:

- a) czas pracy jednostki i_z przed godziną t jest nie mniejszy od minimalnego (warunek (4.10)) lub jednostka i_z jest w godzinie ($t - 1$) odstawiona,
- b) pozostałe w ruchu jednostki (z pominięciem jednostki i_z) są w stanie pokryć zapotrzebowanie i rezerwę wirującą w chwili t (warunek (4.8)),

oblicza się zyski z odstawienia ze wzoru (2.17), dla czasów postoju w rezerwie $t_{pi} = t_{pmini}, (t_{pmini} + 1), \dots, (T - t + 1)$. Dla każdej jednostki i_o , o stanie wyjściowym „odstawiona” w chwili t , przy spełnionych warunkach:

- a) czas postoju jednostki i_o przed godziną t jest nie mniejszy od minimalnego (warunek (4.9)) lub jednostka i_o jest w godzinie ($t - 1$) załączona,
- b) suma minimów technicznych załączonych do ruchu jednostek, z uwzględnieniem jednostki i_o , jest mniejsza od zapotrzebowania w chwili t (warunek (4.7)),

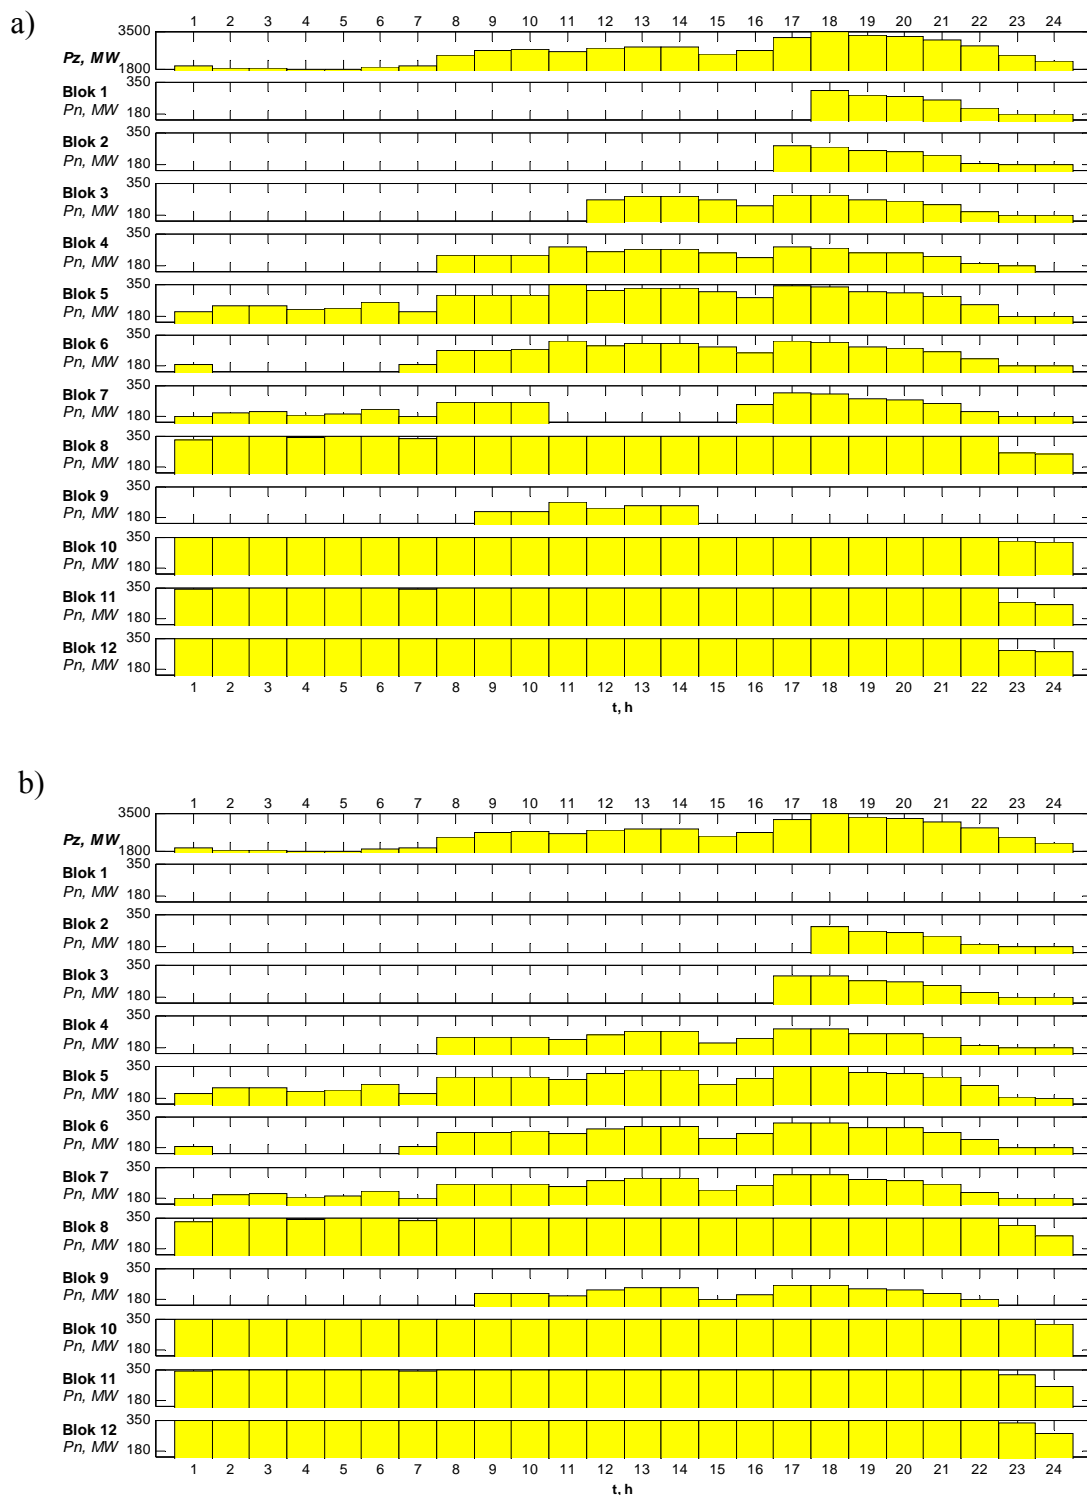
oblicza się zyski z uruchomienia ze wzoru (2.18), dla czasów pracy po rozruchu $t_{ri} = t_{rmini}, (t_{rmini} + 1), \dots, (T - t + 1)$. Blok i_x , dla którego otrzymano maksymalny dodatni zysk $Z_{oi}(t, t_{piy})$ lub $Z_{ui}(t, t_{riy})$, należy odstawić na czas t_{piy} lub uruchomić na czas t_{riy} . Po zmianie stanu bloku i_x w godzinie t ponownie rozpatruje się odstawienie lub uruchomienie każdego z pozostałych bloków wyznaczając zyski (2.17) oraz (2.18) i typując kolejne bloki do odstawienia lub uruchomienia. Tę procedurę powtarza się dla godziny t do momentu, gdy maksymalny zysk staje się ujemny. W przypadku ujemnego maksymalnego zysku kontroluje się czy załączone w godzinie t jednostki zdolne są do pokrycia zapotrzebowania $P_z(t)$ z uwzględnieniem rezerwy $P_{rw}(t)$. Jeśli nie, do uruchomienia lub odstawienia wybiera się jednostkę wykazującą największy (ujemny) zysk. Koszty rozruchu, w sytuacji gdy jednostka pozostaje odstawiana do końca okresu optymalizacji T , oblicza się ze wzoru (4.4).

Szczegółowy algorytm charakterystyk czasów granicznych zaprezentowano poniżej:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych generacji jednostek P_{nmini} i P_{nmaxi} , charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie t_{pmini} i minimalnych czasów pracy po rozruchu t_{rmini} .
2. Ustalenie stanów wyjściowych jednostek w godzinie $t = 1$.
3. Przyjmij $t = 1$.
4. Jeśli $t \leq T$ powtarzaj:
 - 4.1. Dla $i = 1$ do N powtarzaj:

- 4.1.1. Jeśli jednostka i -ta w godzinie t jest odstawiona oraz załączenie jednostki i -tej nie spowoduje przekroczenia ograniczenia (4.7), wykonaj:
- 4.1.1.1. Zmień tymczasowo stan jednostki i -tej na „załączona” w godzinie t .
 - 4.1.1.2. Ekonomiczny rozdział obciążeń na załączone w godzinie t jednostki metodą równych przyrostów względnych kosztów zmiennych.
 - 4.1.1.3. Wyznaczenie kosztów rozruchu jednostki i -tej.
 - 4.1.1.4. Jeśli czas postoju jednostki i -tej przed uruchomieniem w godzinie t jest nie mniejszy od minimalnego lub jednostka ta była załączona w godzinie $(t - 1)$, wykonaj:
 - 4.1.1.4.1. Dla $t_{ri} = t_{rmini}$ do $(T - t + 1)$ wyznacz zysk z uruchomienia jednostki i -tej w godzinie t na czas $t_{ri} - Z_{ui}(t, t_{riy})$.
- 4.1.2. Jeśli jednostka i -ta w godzinie t jest załączona oraz odstawienie jednostki i -tej nie spowoduje przekroczenia ograniczenia (4.8), wykonaj:
- 4.1.2.1. Ekonomiczny rozdział obciążeń na załączone w godzinie t jednostki metodą równych przyrostów względnych kosztów zmiennych.
 - 4.1.2.2. Jeśli czas pracy jednostki i -tej przed godziną t jest nie mniejszy od minimalnego lub jednostka ta była odstawiona w godzinie $(t - 1)$, wykonaj:
 - 4.1.2.2.1. Dla $t_{pi} = t_{pmini}$ do $(T - t + 1)$ wykonaj:
 - 4.1.2.2.1.1. Wyznaczenie kosztów rozruchu jednostki i -tej.
 - 4.1.2.2.1.2. Wyznaczenie zysku z odstawienia jednostki i -tej w godzinie t na czas $t_{pi} - Z_{oi}(t, t_{riy})$.
- 4.2. Jeśli maksymalny dodatni zysk (2.17) lub (2.18) uzyskano z uruchomienia jednostki i_x w chwili t na czas t_{riy} , załącz jednostkę i_x w chwili t na czas t_{riy} .
- 4.3. Jeśli maksymalny dodatni zysk (2.17) lub (2.18) uzyskano z odstawienia jednostki i_x w chwili t na czas t_{piy} , odstaw jednostkę i_x w chwili t na czas t_{piy} .
- 4.4. Jeśli nie osiągnięto dodatniego zysku, wykonaj:
- 4.4.1. Jeśli warunek (4.8) jest niespełniony, powtarzaj do momentu, gdy będzie on spełniony:
 - 4.4.1.1. Jeśli maksymalny zysk (2.18) uzyskano z uruchomienia jednostki i_x w chwili t na czas t_{riy} , załącz jednostkę i_x w chwili t na czas t_{riy} .
 - 4.4.2. Jeśli warunek (4.7) jest niespełniony, powtarzaj do momentu, gdy będzie on spełniony:
 - 4.4.2.1. Jeśli maksymalny zysk (2.17) uzyskano z odstawienia jednostki i_x w chwili t na czas t_{piy} , odstaw jednostkę i_x w chwili t na czas t_{piy} .
- 4.5. Podstaw $t = t + 1$.

Algorytm ten jest podobny do zaprezentowanego w rozdziale 3 pt.: „Kolejność postępowania przy dobieraniu optymalnego zestawu urządzeń wytwórczych” pracy [Tor62], przy czym w algorytmie Toronia, w stanie wyjściowym wszystkie jednostki są załączone, co wobec dużych wartości minimów technicznych jednostek pracujących w KSE może być nierealne (przekroczenie warunku (4.7)).



Rys. 4.27. Harmonogramy pracy jednostek wytwórczych otrzymane metodą charakterystyk czasów granicznych: a) z uwzględnieniem na etapie działania algorytmu warunków minimalnych czasów odstawień i pracy po uruchomieniu, b) bez uwzględnienia tych warunków. Źródło: opracowanie własne.

Harmonogramy pracy JW otrzymane tą metodą przedstawiono na rys. 4.27 a). Całkowity koszt tego rozwiązania wynosi $F_P = 2\,662\,536$ zł i jest o $\Delta F_{P\%} = 3,21\%$ (tj. 82 733

zł) większy od kosztu rozwiązania P_{nopt} . Lepsze wyniki otrzymano dopuszczając na etapie działania algorytmu przekroczenia warunków minimalnych czasów postoju i pracy po uruchomieniu. Algorytm w tym przypadku jest identyczny z przedstawionym powyżej po usunięciu punktów 4.1.1.4 oraz 4.1.2.2. Otrzymane rozwiązanie było niedopuszczalne – jednostka nr 9 o godzinie 11 i 15 była odstawiona na jedną godzinę. Zmieniając „ręcznie” stany tej jednostki w godzinie 11 i 15 na „załączona” otrzymano rozwiązanie dopuszczalne o koszcie $F_P = 2\,598\,357$ zł, gorszym o $\Delta F_{p\%} = 0,72\%$ (tj. 18 554 zł) od kosztu rozwiązania P_{nopt} . Rozwiązanie to zobrazowano na rys. 4.27 b).

Wnioski

1. Spośród przetestowanych algorytmów ewolucyjnych najlepsze działanie wykazywał:
 - a) AE z reprezentacją binarną czasów odstawień i załączeń RB2, strategią kary, mutacją binarną równomierną MBR, krzyżowaniem jednopunktowym K1P i operatorem transpozycji OT (wariant AE3 w tablicy 4.10). Częstość znalezienia rozwiązania P_{nopt} w tym przypadku wynosiła $c_{opt} = 0,4$, a koszt najgorszego rozwiązania z dziesięciu uruchomień algorytmu był większy od kosztu rozwiązania P_{nopt} tylko o $\Delta F_{P_{max}\%} = 0,018\%$ (458 zł). Do znalezienia rozwiązania P_{nopt} algorytm potrzebował średnio 33 800 odwołań do funkcji kosztu i 47 min.
 - b) AE z reprezentacją całkowitoliczbową czasów odstawień i załączeń RC, strategią kary, mutacją binarną równomierną MBR, krzyżowaniem jednopunktowym K1P i operatorem transpozycji OT (wariant AE4). Mimo mniejszej częstości znalezienia optimum ($c_{opt} = 0,2$), rozwiązania końcowe były równie stabilne jak w AE z reprezentacją RB2 ($\sigma_{F_P} = 173$). Porównywalne były też wskaźniki l_{opt} oraz t_{opt} .

Algorytmy z reprezentacją binarną stanów pracy jednostek RB1 wykazywały słabsze działanie (inaczej jak w zadaniu uproszczonym). Różnica pomiędzy kosztem najgorszego rozwiązania z 10 uruchomień AE z reprezentacją RB1, a kosztem rozwiązania P_{nopt} wynosiła: $\Delta F_{P_{max}\%} = 0,198\%$ (5115 zł) – w przypadku strategii naprawy deterministycznej oraz $\Delta F_{P_{max}\%} = 0,116\%$ (2994 zł) – w przypadku strategii kary.

Przebiegi procesów ewolucyjnych dla różnych reprezentacji zmiennych, zobrazowane na rys. 4.22, są podobne. Rozwiązania dopuszczalne znajdowane były w mniej niż stu generacjach AE (10 000 odwołań do funkcji kosztu).

2. Spośród przetestowanych algorytmów symulowanego wyżarzania najlepsze okazały się:
 - a) algorytm SW z reprezentacją binarną stanów pracy jednostek RB1, strategią naprawy deterministycznej, schematem Aartsa, mutacją binarną MB3 i operatorem transpozycji (wariant SW1 w tablicy 4.12). Częstość znalezienia rozwiązania P_{nopt} w tym przypadku wyniosła $c_{opt} = 0,4$. Rozwiązania były stabilne, zbliżone do rozwiązań otrzymanych w AE (patrz p. 1 a)). Liczba odwołań do funkcji kosztu l_{opt} była jednak ok. dwukrotnie większa niż w najlepszych wariantach AE, a czas t_{opt} ok. 3,5-krotnie dłuższy.

- b) algorytm SW z reprezentacją binarną stanów pracy jednostek RB1, strategią kary, schematem Aartsa, mutacją binarną MB3 i operatorem transpozycji (wariant SW2). Częstość znalezienia rozwiązania P_{nopt} w tym przypadku była najwyższa spośród wszystkich testowanych algorytmów: $c_{opt} = 0,5$, chociaż rozwiązania nie były tak stabilne jak w algorytmie SW ze strategią naprawy i w najlepszych AE ($\sigma_{F_p} = 718$). Pozostałe wskaźniki: l_{opt} i t_{opt} były porównywalne do otrzymanych w algorytmie SW ze strategią naprawy.

Algorytmy symulowanego wyżarzania z reprezentacjami: binarną i całkowitoliczbową czasów załączeń i odstawień wykazywały słabe działanie (patrz rys. 4.28).

Algorytmy SW z reprezentacją RB1 szybko zbiegały się do punktów dopuszczalnych (rys. 4.24): algorytm SW ze strategią SND potrzebował od 700 do 3000 odwołań do funkcji kosztu, aby znaleźć rozwiązanie dopuszczalne, natomiast SW ze strategią SFK – od 140 do 1000 odwołań. Znacznie wolniej działały algorytmy SW z reprezentacją RB2 (4500 ÷ 9000 odwołań) oraz RC (5500 ÷ 20 000 odwołań).

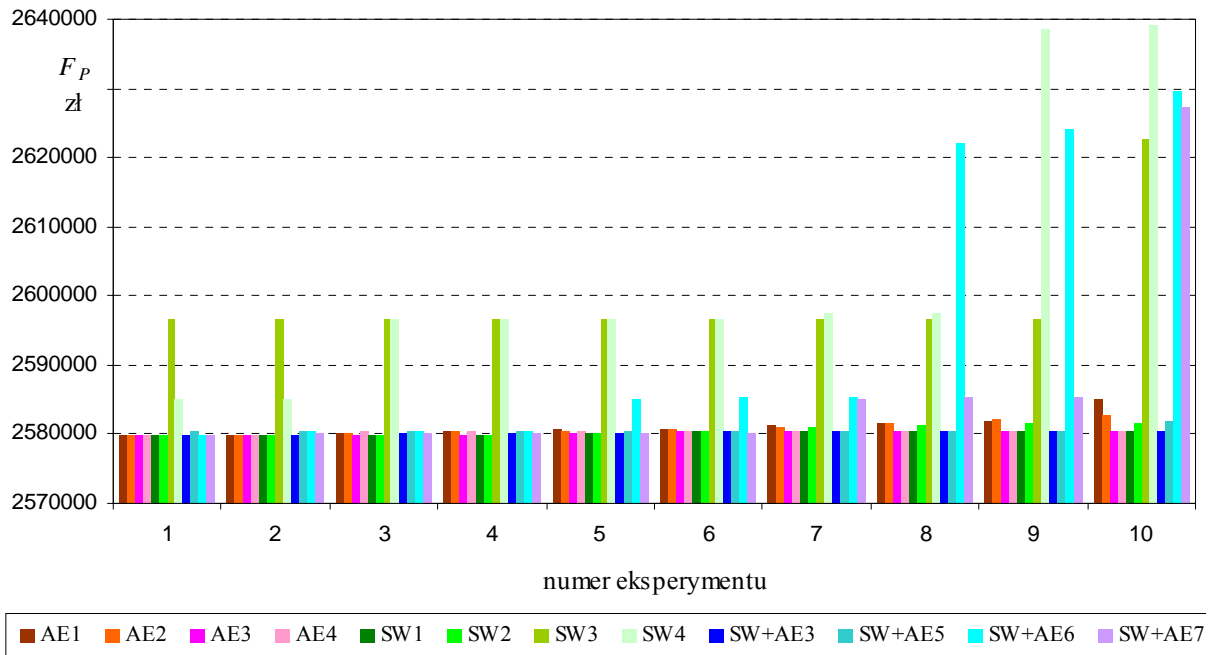
3. Spośród testowanych algorytmów SW+AE najlepiej działały:
- a) algorytm SW+AE z reprezentacją binarną stanów pracy jednostek RB1, strategią naprawy deterministycznej, mutacją binarną MB3, operatorem transpozycji OT, krzyżowaniem jednopunktowym K1P i strategią rekombinacji SRN (wariant SW+AE3 w tablicy 4.13). Częstość znalezienia rozwiązania P_{nopt} dla tego wariantu wynosiła $c_{opt} = 0,2$, ale różnica pomiędzy kosztem najgorszego rozwiązania a kosztem rozwiązania P_{nopt} była niewielka – $\Delta F_{P_{max}\%} = 0,020\%$ (522 zł). Liczba odwołań do funkcji kosztu w tym przypadku – $l_{opt} = 57\,925$, a czas – $t_{opt} = 1\text{ h }35\text{ min}$.
- b) algorytm SW+AE z reprezentacją binarną stanów pracy jednostek RB1, strategią naprawy deterministycznej, mutacją binarną MB3, operatorem transpozycji OT, krzyżowaniem jednopunktowym K1P i strategią mikrowyżarzania (wariant SW+AE4). Częstość znalezienia rozwiązania P_{nopt} dla tego wariantu wynosiła $c_{opt} = 0,3$. Wyniki były mniej stabilne niż w wariacie SW+AE3 ($\sigma_{F_p} = 677$), pozostałe wskaźniki były porównywalne.

Inne warianty tego algorytmu nie dawały satysfakcjonujących rezultatów.

Cechą charakterystyczną działania algorytmu SW+AE są częste przeskoki na niższe poziomy kosztowe, spowodowane utrzymaniem się wysokiej temperatury wyżarzania w schemacie Kirkpatricka. Rozwiązania stabilizują się na trzecim poziomie kosztowym znacznie później niż w AE i SW. Pomysł strategii rekombinacji wg kryterium odległościowego SRO okazał się chybiony – w końcowej fazie działania algorytmu rekombinują ze sobą zawsze te same punkty, rozlokowane w sąsiednich minimach lokalnych. Krzyżowanie bliskich punktów daje punkty potomne leżące w sąsiedztwie punktów rodzicielskich, w obszarach przyciągania tych samych minimów lokalnych. Punkty potomne zostają sprowadzone do minimów poprzez operację przesunięcia w pętli wewnętrznej. W strategii rekombinacji losowej SRL dopuszcza się krzyżowanie dowolnych punktów, co pozwala intensywniej penetrować przestrzeń rozwiązań niż w strategii SRO. W strategii rekombinacji z najlepszym punktem SRN, populacja bieżąca

szybciej zbiega się do najlepszego na danym poziomie temperaturowym punktu, ponieważ materiał genetyczny tego punktu jest w operacji krzyżowania sztucznie wprowadzany do każdego punktu potomnego. Oznacza to intensywne przeszukiwanie przestrzeni wokół najlepszego znalezione dotychczas rozwiązania. Jeszcze szybszą zbieżność otrzymuje się stosując strategię mikrowyżarzania SMW, gdzie każdy proces wyżarzania startuje z najlepszego znalezione dotychczas punktu.

Koszty najlepszych rozwiązań znalezionych w poszczególnych uruchomieniach testowanych algorytmów przedstawiono na rys. 4.28.



Rys. 4.28. Koszty najlepszych rozwiązań w poszczególnych uruchomieniach testowanych algorytmów. Źródło: opracowanie własne.

- Całkowity średni czas działania algorytmów ewolucyjnych wynosił ok. 3 h, algorytmów symulowanego wyżarzania – ok. 5 h, algorytmów SW+AE – ok. 3,5 h. Znacznie szybsze działanie AE i algorytmu SW+AE od algorytmu SW spowodowane jest równoległą strukturą AE, w których przetwarzana jest cała populacja rozwiązań, a nie pojedyncze punkty. Zaletą Matlaba są szybkie operacje arytmetyczne na strukturach danych zorganizowanych w tablice (macierze), co można było wykorzystać w AE operujących na tablicach chromosomów. Przemawia to na korzyść AE i uwydatnia się jeszcze bardziej w przypadku realizacji algorytmów na maszynach o architekturze równoległej.
- Algorytm z twardą selekcją, będący szczególną postacią algorytmu SW z zerowym prawdopodobieństwem akceptacji punktów próbných gorszych od punktów bieżących, nie posiada mechanizmu ucieczki z minimów lokalnych. Skutkuje to znacznie gorszymi rezultatami. Zwiększenie liczby iteracji nie poprawi działania tego algorytmu. Metoda Monte Carlo wykazuje jeszcze gorszą skuteczność.
- Algorytm charakterystyk czasów granicznych, jako metoda uproszczona DSJW, w której nie uwzględnia się zmienności strumienia zysków podczas pracy lub postoju jednostek

oraz przyjmuje się jednakowy przyrost kosztów zmiennych przed i po odstawieniu (uruchomieniu) jednostki, nie osiąga tak dobrych rezultatów jak proponowane algorytmy optymalizacyjne w swoich najlepszych wariantach. Ponadto algorytm ten został opracowany dla dużych systemów elektroenergetycznych, a nie dla elektrowni. Korzystając z tego algorytmu lepsze wyniki osiągnięto pomijając ograniczenia minimalnych czasów postoju i pracy JW, a otrzymane rozwiązanie niedopuszczalne korygując heurystycznie (rys. 4.27).

W tabelicy 4.14 zestawiono rezultaty obliczeń optymalizacyjnych w formie syntetycznej.

Tablica 4.14. Zestawienie najlepszych rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni w formie syntetycznej. Źródło: opracowanie własne.

Najlepszy wariant algorytmu	F_{Pmin} zł	F_{Pmax} zł	\bar{F}_P zł	$\Delta F_{Pmax\%}$ %	σ_{F_P} zł	C_{opt}	l_{opt}	t_{opt} h
AE	2 579 803	2 580 261	2 580 051	0,018	228	0,4	33 800	0,78
SW	2 579 803	2 580 325	2 580 064	0,020	243	0,4	64 215	2,89
SW+AE	2 579 803	2 580 325	2 580 103	0,020	201	0,2	57 925	1,58
Twardej selekcji	2 769 269	2 867 751	2 818 197	11,161	49 241	0,0	-	-
Monte Carlo	brak rozwiązań dopuszczalnych							
Charakterystyk czasów granicznych	2 662 536	2 662 536	2 662 536	3,206	0	0,0	-	-
Charakterystyk czasów granicznych z korektą heuryst.	2 598 357	2 598 357	2 598 357	0,719	0	0,0	-	-

4.5. MODELE OPTIMALIZACYJNE DO EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ NA POZIOMIE ELEKTROWNI – PODEJŚCIE ZINTEGROWANE

W podejściu zintegrowanym ERO-z proponuje się dwa algorytmy optymalizacyjne:

- kompleksowy – AE optymalizujący harmonogram pracy jednostek oraz ich obciążenia w całym okresie optymalizacji T ,
- sekwencyjny – AE optymalizujący obciążenia jednostek w pojedynczych godzinach i uruchamiany dla każdej godziny okresu T .

Proponuje się zmiennopozycyjną reprezentację zmiennych, którymi są obciążenia jednostek wytwórczych. Stosuje się najefektywniejsze, sprawdzone w zadaniu ERO-k operatory genetyczne (w wersji zmiennopozycyjnej) oraz wypracowane metody postępowania z rozwiązaniami naruszającymi ograniczenia.

Jako operatory genetyczne używa się:

- mutację zmiennopozycyjną zależną od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MZ1,
- mutację zmiennopozycyjną nierównomierną MZN,
- mutację zmiennopozycyjną równomierną MZR,
- transpozycję OT,
- krzyżowanie jednopunktowe K1P.

Metodą selekcji we wszystkich algorytmach jest turniej binarny. Podobnie jak w modelach optymalizacyjnych ERO-k, ograniczenia funkcji kosztu eliminuje się stosując strategię naprawy rozwiązań niedopuszczalnych oraz strategię z funkcją kary.

Wyniki obliczeń optymalizacyjnych ekonomicznego rozdziału obciążeń z podejściem zintegrowanym zamieszczono w podrozdziale 4.5.3.

4.5.1. KOMPLEKSOWY ALGORYTM EWOLUCYJNY KAE

4.5.1.1. REPREZENTACJA ZMIENNYCH

Zmiennymi w zadaniu ERO są obciążenia poszczególnych jednostek wytwórczych w kolejnych godzinach okresu optymalizacji T . Naturalną, w tym przypadku, jest reprezentacja zmiennopozycyjna: każdy gen chromosomu $z_i(t)$ jest liczbą rzeczywistą, interpretowaną jako obciążenie jednostki i -tej w chwili t . Aby uwzględnić stan „jednostka odstawiona” wprowadza się dodatkową wartość genu – 0. Stąd wynikają zakresy zmienności genów:

$$\forall i, t : [P_{n \min i} \leq z_i(t) \leq P_{n \max i}] \vee [z_i(t) = 0] \quad (4.134)$$

Przestrzeń rozwiązań, przy założeniu dokładności określania obciążeń JW na poziomie δ_p , obejmuje N_p punktów:

$$N_p = \left\{ \prod_{i=1}^N \left[\frac{1}{\delta_p} (P_{n_{\max i}} - P_{n_{\min i}}) + 2 \right] \right\}^T \quad (4.135)$$

Liczba ta dla $\delta_p = 1$ MW, $N = 12$, $P_{n_{\min i}} = 180$ MW, $P_{n_{\max i}} = 350$ MW jest rzędu 10^{643} .

Sposób kodowania w kompleksowym AE przedstawiono w tabelicy 4.15.

Tablica 4.15. Sposób kodowania w kompleksowym algorytmie ewolucyjnym stosowanym do ERO-z. Źródło: opracowanie własne.

Postać chromosomu:	$z_1(1)$	$z_2(1)$...	$z_N(1)$	$z_1(2)$	$z_2(2)$...	$z_N(2)$...	$z_1(T)$	$z_2(T)$...	$z_N(T)$
Przykładowy chromosom:	0	192,...	...	329,...	311,...	0	...	273,...	...	234,...	0	...	302,...
Znaczenie genów:	$P_{n1}(1)$	$P_{n2}(1)$...	$P_{nN}(1)$	$P_{n1}(2)$	$P_{n2}(2)$...	$P_{nN}(2)$...	$P_{n1}(T)$	$P_{n2}(T)$...	$P_{nN}(T)$

gdzie: $z_i(t)$ – liczba rzeczywista reprezentująca obciążenie jednostki i -tej w chwili t .

Wartości funkcji binarnych $\alpha_i(t)$ wynikają z wartości genów:

$$\alpha_i(t) = \begin{cases} 1, & \text{gdy } z_i(t) \neq 0 \\ 0, & \text{gdy } z_i(t) = 0 \end{cases} \quad (4.136)$$

Dla liczby jednostek $N = 12$ i horyzontu optymalizacji $T = 24$ h chromosom posiada 288 genów (liczb rzeczywistych).

4.5.1.2. OPERATORY GENETYCZNE

W odróżnieniu od zadania ERO-k, w zadaniu ERO-z operatory genetyczne powinny zapewniać przeszukiwanie nie tylko przestrzeni stanów jednostek („jednostka załączona” – „jednostka odstawiona”), ale także przestrzeni obciążeń jednostek (w zadaniu ERO-k obciążenia były ustalane w sposób deterministyczny). Efektywną eksplorację tych przestrzeni zapewniają specjalizowane operatory genetyczne oraz algorytm naprawy. Do penetracji przestrzeni stanów proponuje się operator mutacji MZ1 oraz operator transpozycji, natomiast do penetracji przestrzeni obciążeń – operator mutacji MZN. Krzyżowanie zapewnia przeszukiwanie obu przestrzeni. Operatory genetyczne działają na osobnikach wybranych z populacji losowo.

Mutacja zmiennopozycyjna zależna od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MZ1

Mutacja ta jest analogiczna do mutacji binarnej MB3 (opisanej w podrozdziale 4.4.1.1.2). Dla każdego chromosomu zmiennopozycyjnego ch określa się łańcuch binarny $B = [b_1(1), \dots, b_N(1), b_1(2), \dots, b_N(2), \dots, b_1(T), \dots, b_N(T)]$, gdzie $b_i(t)$ – wartość binarna kodująca stan jednostki i -tej w chwili t , równoznaczna z $\alpha_i(t)$. Łańcuch B stanowi binarną reprezentację stanów pracy jednostek RB1 wynikającą z chromosomu zmiennopozycyjnego ch . Łańcuch ten podlega mutacji binarnej MB3. Wartości genów $z_i(t)$ po mutacji określa się następująco:

$$z_i'(t) = \begin{cases} z_i(t), & \text{jeśli bit } b_i(t) \text{ nie zmienia wartości po mutacji} \\ r_r \in \langle P_{n \min i}, P_{n \max i} \rangle, & \text{jeśli bit } b_i(t) \text{ zmienia wartość z 0 na 1 w wyniku mutacji} \\ 0, & \text{jeśli bit } b_i(t) \text{ zmienia wartość z 1 na 0 w wyniku mutacji} \end{cases} \quad (4.137)$$

gdzie: r_r – losowa liczba rzeczywista o rozkładzie jednostajnym.

Jednostkom wytwórczym, które w wyniku mutacji zmieniają stan z „odstawiona” na „załączona” przypisuje się obciążenia przypadkowe.

Operator MZ1 realizuje funkcja MUTACJA_Z1.m.

Mutacja zmiennopozycyjna nierównomierna MZN

Mutacja MZN jest zmiennopozycyjną wersją mutacji całkowitoliczbowej nierównomiernej MCN. Stopień modyfikacji chromosomu (przesunięcia punktu w przestrzeni obciążeń jednostek) zależy od zaawansowania procesu ewolucyjnego i ułatwia jego dokładne dostrojenie się. Zadaniem tego operatora jest zmiana obciążenia jednostki reprezentowanej przez wybrany losowo do mutacji gen $z_i(t)$. Jeśli wartość genu $z_i(t)$ równa jest 0 nie ulga on zmianie. Po mutacji gen $z_i(t)$ przyjmuje wartość:

$$z_i'(t) = \begin{cases} z_i(t) + f_{\Delta}(l_{gen}, P_{n \max i} - z_i(t)), & \text{jeśli } z_i(t) \neq 0 \wedge r_b = 0 \\ z_i(t) - f_{\Delta}(l_{gen}, z_i(t) - P_{n \min i}), & \text{jeśli } z_i(t) \neq 0 \wedge r_b = 1 \\ 0, & \text{jeśli } z_i(t) = 0 \end{cases} \quad (4.138)$$


gdzie: r_b – losowa wartość binarna.

Funkcja $f_{\Delta}(l_{gen}, y)$ przyjmuje wartości rzeczywiste z zakresu $\langle 0, y \rangle$, przy czym prawdopodobieństwo, że $f_{\Delta}(l_{gen}, y)$ jest bliskie 0 wzrasta ze wzrostem licznika generacji l_{gen} . Zastosowano funkcję postaci [Mic96a]:

$$f_{\Delta}(l_{gen}, y) = y \left[1 - r_r^{(1 - l_{gen} / L_{gen})^n} \right] \quad (4.139)$$

gdzie: r_r – losowa liczba rzeczywista o rozkładzie jednostajnym z przedziału $\langle 0, 1 \rangle$;
 n – parametr określający stopień zależności od licznika generacji, przyjęto $n = 2$.

Na rys. 4.29 zobrazowano przykładowy przebieg funkcji $f_{\Delta}(l_{gen}, y)$.



Rys. 4.29. Przebieg funkcji $f_{\Delta}(l_{gen}, y)$ dla $n = 2$ i $y = 100$. Źródło: opracowanie własne.

Chromosom po mutacji przyjmuje postać: $ch = [z_1(1), \dots, z_i'(t), \dots, z_N(T)]$. Operator MZN utrzymuje geny w zakresie ich zmienności.

Mutację MZN zaimplementowano w funkcji MUTACJA_ZN.m.

Pozostałe operatory

Jako operator krzyżowania wybrano krzyżowanie jednopunktowe, dające dobre efekty w zadaniu ERO-k. Miejsca cięcia chromosomów wypadają w tym przypadku pomiędzy genami. Krzyżowanie to realizuje funkcja KRZYZ_1P.m.

Stosuje się także operację transpozycji, zamieniającą miejscami fragmenty chromosomu kodujące harmonogramy wybranej losowo pary jednostek. Schemat działania transpozycji pokazano na rys. 4.8. Zadanie jakie postawiono przed tym operatorem to penetracja minimów lokalnych przestrzeni stanów JW, podobnie jak w ERO-k. Transpozycję realizuje funkcja TRANSPOZYCJA.m.

4.5.1.3. METODY ELIMINACJI OGRANICZEŃ FUNKCJI KOSZTU

Reprezentacja zmiennych oraz stosowane operatory genetyczne zapewniają dotrzymanie ograniczeń zakresu generacji poszczególnych jednostek (4.6). Ograniczenia zakresu generacji grupy jednostek (4.7) i (4.8) oraz minimalnego dopuszczalnego czasu postoju i pracy po rozruchu JW (4.9) i (4.10) uwzględnia się w zastępczych funkcjach kosztu obejmujących składniki kary za przekroczenia ograniczeń.

Dla każdej chwili $t = 1, 2, \dots, T$ określa się skład grupy jednostek będących w ruchu (skład ten wynika z chromosomu; zalicza się do niego JW, dla których zachodzi $z_i(t) \neq 0$). Chromosomy nie spełniające ograniczeń zakresu generacji grupy JW (4.7) lub (4.8) – $ch \notin D_1$, oceniane są za pomocą zastępczej funkcji kosztu postaci (4.94). Osobniki te nie podlegają dalszemu karaniu za przekroczenia warunków minimalnego czasu postoju i pracy (4.9) i (4.10) oraz naprawie.

Miarą oceny osobników spełniających ograniczenia (4.7) i (4.8), a naruszających ograniczenia dopuszczalnych czasów postoju (4.9) lub pracy (4.10) jest zastępcza funkcja kosztu postaci (4.88). Zastępczy koszt osobników $ch \in D_1 - D_2$ jest w każdym przypadku większy od kosztu osobników $ch \in D_1 \cap D_2$ i mniejszy od zastępczego kosztu osobników $ch \notin D_1$.

Rozwiązania dopuszczalne ze względu na wszystkie przyjęte ograniczenia z wyjątkiem warunku bilansu mocy (4.5) podlegają naprawie. Dla każdej chwili t należy sprawdzić warunek bilansu i skorygować obciążenia jednostek tak, aby był on spełniony z pewnym błędem:

$$\left| \sum_{i=1}^N [\alpha_i(t) P_{ni}(t)] - P_z(t) \right| \leq \delta_p \quad (4.140)$$

Dobór δ_p analizuje się w podrozdziale 4.6. W najprostszym przypadku naprawa może polegać na zmianie obciążeń jednostek załączonych w chwili t , wybranych w sposób losowy lub deterministyczny. Bardziej wyszukany algorytm naprawy może być podproces ewolucyjny, w którym minimalizuje się wielkość niezbilansowania. Chromosomy kodują obciążenia jednostek załączonych w chwili t (nie uwzględnia się jednostek w postoju), a operatory genetyczne przeszukują przestrzeń obciążeń tych jednostek, do momentu spełnienia warunku (4.5). Obciążenia te oczywiście nie byłyby optymalne w sensie kryterium kosztowego (4.2), ale optymalizacja tego kryterium zachodzi na poziomie wyższym – w głównym procesie ewolucyjnym. Podejście takie, z nadrzędnym i podrzędnym procesem ewolucyjnym może jednak znacznie wydłużyć czas obliczeń.

Strategie kary i naprawy zaprogramowane są w funkcji KOSZT3.m.

Strategia naprawy z kryterium jednostkowych kosztów zmiennych SN1

Proponuje się losowo – deterministyczny algorytm naprawy, który preferuje w przypadku nadwyżki mocy wytwarzanej odciażanie jednostek mniej ekonomicznych, a w przypadku deficytu mocy dociążenie jednostek bardziej ekonomicznych. Miarą ekonomiczności jednostki jest jej jednostkowy koszt zmienny przy obciążeniu osiągalnym $k_j(P_{nmax})$. Określa się prawdopodobieństwa selekcji jednostek do dociążenia lub odciażenia, które zależą od pozycji jednostek na liście rankingowej L_r . Lista obejmuje tylko te jednostki, które są załączone w chwili t i jest uporządkowana rosnąco względem $k_j(P_{nmax})$, w przypadku nadwyżki mocy wytwarzanej lub malejąco, w przypadku deficytu.

Przyjęto, że prawdopodobieństwo selekcji jednostki do dociążenia zależy proporcjonalnie od jej pozycji na liście rankingowej:

$$p_s(g) = ag + b \quad (4.141)$$

gdzie: g – pozycja jednostki na liście rankingowej L_r , $g = 1, 2, \dots, N_r$; N_r – liczba jednostek na liście rankingowej, $N_r \in \{1, 2, \dots, N\}$; a, b – współczynniki funkcji liniowej.

Współczynniki a i b należy dobrać w ten sposób, aby był spełniony warunek:

$$\sum_{g=1}^{N_r} p_s(g) = 1 \quad (4.142)$$

W przypadku jednakowych prawdopodobieństw selekcji jednostek, niezależnie od ich rang – $\forall g: p_s(g) = 1/N_r$ – napór selekcyjny jest najmniejszy. Z drugiej strony największy napór występuje w przypadku, kiedy prawdopodobieństwo selekcji ostatniej na liście L_r jednostki jest zerowe – $p_s(N_r) = 0$. Prawdopodobieństwo selekcji jednostki położonej dokładnie w środku listy L_r – o randze $g = (N_r+1)/2$ – we wszystkich przypadkach wynosi:

$$\forall a, b: p_s\left(\frac{N_r+1}{2}\right) = \frac{1}{N_r} \quad (4.143)$$

Niech m_r oznacza stosunek prawdopodobieństwa selekcji pierwszej jednostki na liście L_r do jednostki ostatniej:

$$m_r = \frac{p_s(1)}{p_s(N_r)} \quad (4.144)$$

Zestawiając równania (4.143) z (4.144) i wykorzystując równanie (4.141) otrzymujemy układ:

$$\begin{cases} p_s\left(\frac{N_r+1}{2}\right) = \frac{1}{N_r} \\ p_s(1) = m_r p_s(N_r) \end{cases} \Rightarrow \begin{cases} \frac{N_r+1}{2}a + b = \frac{1}{N_r} \\ a + b = m_r(N_r a + b) \end{cases} \quad (4.145)$$

który po rozwiązaniu daje:

$$a = \frac{2(m_r - 1)}{N_r[1 - N_r(m_r + 1) + m_r]} \quad (4.146)$$


$$b = \frac{2(1 - N_r m_r)}{N_r [1 - N_r (m_r + 1) + m_r]} \quad (4.147)$$

Stąd wzór na prawdopodobieństwo selekcji:

$$p_s(g) = \frac{2[(m_r - 1)g + 1 - N_r m_r]}{N_r [1 - N_r (m_r + 1) + m_r]} \quad (4.148)$$

Parametr $m_r \geq 1$ pozwala sterować naporem selekcyjnym. Dla $m_r = 1$ brak naporu; wzrost m_r zwiększa napór.

Prawdopodobieństwo selekcji jednostek do odciążania, w przypadku gdy suma obciążeń JW jest większa od zapotrzebowania, liczy się z tego samego wzoru (4.148), przy czym lista rankingowa uporządkowana jest malejąco (niższe rangi mają JW mniej ekonomiczne). Prawdopodobieństwa selekcji jednostek zależnie od ich rang i parametru m_r przedstawiono na rys. 4.30.



Rys. 4.30. Prawdopodobieństwo selekcji jednostek dla $N_r = 10$, w zależności od rangi g i parametru sterującego m_r . Źródło: opracowanie własne.

Algorytm naprawy dla $t = 1, 2, \dots, T$ prezentuje się następująco:

1. Jeśli $P_z(t) - \sum_{i=1}^N [\alpha_i(t) P_{ni}(t)] > \delta_P$, wykonaj:
 - 1.1. Utwórz listę rankingową L_r uporządkowaną rosnąco względem $k_j(P_{nmax})$ jednostek załączonych w chwili t .
 - 1.2. Wyznacz prawdopodobieństwa selekcji jednostek do dociążania ze wzoru (4.148).
 - 1.3. Zdefiniuj przedziały:

$$\Gamma_g = \left(\sum_{k=0}^{g-1} p_s(k), \sum_{k=1}^g p_s(k) \right) \quad g = 1, 2, \dots, N_r \quad (4.149)$$

gdzie: $p_s(0) = 0$.

- 1.4. Powtarzaj do momentu spełnienia warunki bilansu (4.5) z błędem δ_p :
 - 1.4.1. Wylosuj liczbę rzeczywistą z zakresu $(0, 1) - r_r$.
 - 1.4.2. Jeśli $r_r \in \Gamma_g$ ($g = 1, 2, \dots, N_r$), to jednostkę o randze g należy dociążyć o δ_p MW, pod warunkiem, że jej obciążenie nie przekroczy mocy osiągalnej.
2. Jeśli $\sum_{i=1}^N [\alpha_i(t)P_{ni}(t)] - P_z(t) > \delta_p$ wykonaj:
 - 2.1. Utwórz listę rankingową L_r uporządkowaną malejąco względem $k_j(P_{nmax})$ jednostek załączonych w chwili t .
 - 2.2. Wyznacz prawdopodobieństwa selekcji jednostek do odciążania ze wzoru (4.148).
 - 2.3. Zdefiniuj przedziały (4.149).
 - 2.4. Powtarzaj do momentu spełnienia warunki bilansu (4.5) z błędem δ_p :
 - 2.4.1. Wylosuj liczbę rzeczywistą z zakresu $(0, 1) - r_r$.
 - 2.4.2. Jeśli $r_r \in \Gamma_g$ ($g = 1, 2, \dots, N_r$), to jednostkę o randze g należy odciążyć o δ_p MW, pod warunkiem, że jej obciążenie będzie nie mniejsze od minimum technicznego.

Osobniki naprawione zastępują swoje oryginalne wersje z prawdopodobieństwem wymiany p_w .

Strategia naprawy z kryterium przyrostów względnych kosztów zmiennych SN2

W tej deterministycznej strategii, w przypadku deficytu mocy, do dociążenia (o δ_p MW) wybierana jest jednostka o najmniejszym przyroście względnym kosztu zmiennego przy aktualnym obciążeniu (niezerowym). Analogicznie, w przypadku nadwyżki mocy produkowanej, do odciążenia (o δ_p MW) wybiera się jednostkę o największym przyroście względnym kosztu zmiennego przy aktualnym obciążeniu. Jeśli JW osiągnęła minimum techniczne lub moc osiągalną, zmienia się obciążenie kolejnej jednostki, odpowiednio, o największym lub najmniejszym przyroście względnym. Procedurę dociążania (odciążania) powtarza się do momentu spełnienia warunku bilansu mocy z błędem δ_p .

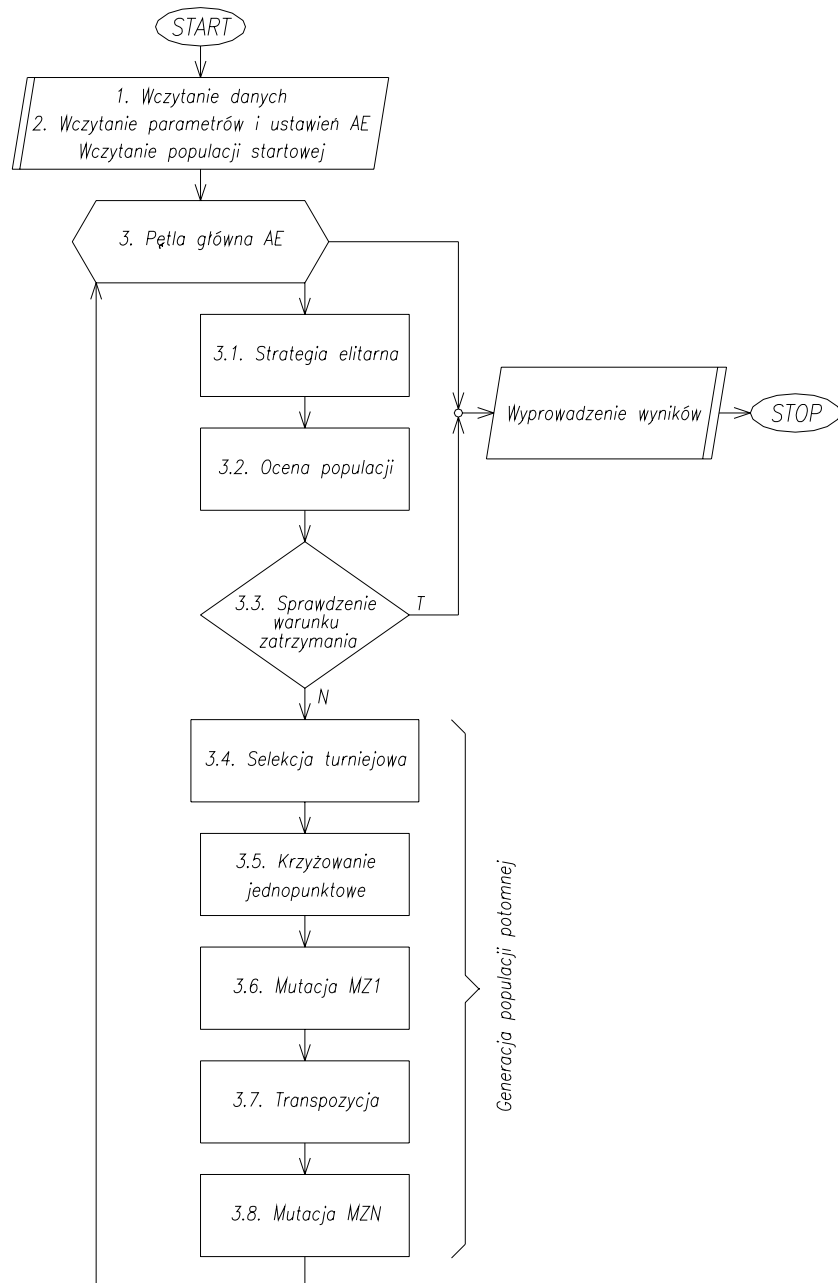
4.5.1.4. SCHEMAT ALGORYTMU OPTIMALIZACYJNEGO

Kompleksowy algorytm ewolucyjny do ERO-z na poziomie elektrowni przedstawia się następująco:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych generacji jednostek P_{nmini} i P_{nmaxi} , charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów

- rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie t_{pmini} i minimalnych czasów pracy po rozruchu t_{rmini} .
2. Określenie parametrów i ustawień algorytmu ewolucyjnego: liczby generacji L_{gen} , liczebności populacji L_{pop} , populacji początkowej \mathcal{P} , parametrów mutacji, prawdopodobieństwa krzyżowania p_k , oczekiwanej liczby transpozycji chromosomu w_t , warunku zatrzymania.
 3. Dla $l_{gen} = 1$ do L_{gen} lub do momentu spełnienia warunku zatrzymania powtarzaj:
 - 3.1. Jeśli $l_{gen} \neq 1$, włączenie do populacji $\mathcal{P}_{l_{gen}}$ najlepszego osobnika rodzicielskiego z populacji $\mathcal{P}_{(l_{gen}-1)}$.
 - 3.2. Ocena populacji $\mathcal{P}_{l_{gen}}$:
 - 3.2.1. Wyznaczenie stopnia naruszenia przez osobniki ograniczeń związanych z zakresem generacji grupy jednostek (4.7) i (4.8).
 - 3.2.2. Wyznaczenie stopnia naruszenia ograniczeń związanych z minimalnym czasem postoju (4.9) i pracy (4.10).
 - 3.2.3. Naprawa osobników dopuszczalnych ze względu na warunki (4.7) ÷ (4.10), a nie spełniających warunku bilansu mocy (4.5). Wyznaczenie kosztów zmiennych, kosztów rozruchów i wartości funkcji kosztu (4.2) dla osobników naprawionych.
 - 3.2.4. Wyznaczenie zastępczej funkcji kosztu dla osobników nie spełniających ograniczenia (4.9) lub (4.10), a spełniających ograniczenia (4.7) i (4.8).
 - 3.2.5. Wyznaczenie zastępczej funkcji kosztu dla osobników nie spełniających ograniczenia (4.7) lub (4.8).
 - 3.2.6. Wymiana osobników niedopuszczalnych ze względu na warunek (4.5) na ich naprawione wersje z prawdopodobieństwem p_w .
 - 3.3. Sprawdzenie warunku zatrzymania.
 - 3.4. Selekcja turniejowa.
 - 3.5. Krzyżowanie jednopunktowe.
 - 3.6. Mutacja MZ1.
 - 3.7. Transpozycja.
 - 3.8. Mutacja MZN.

Schemat blokowy kompleksowego algorytmu ewolucyjnego dla zadania ERO-z zaprezentowano na rys. 4.31.



Rys. 4.31. Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą kompleksowego algorytmu ewolucyjnego. Źródło: opracowanie własne.

4.5.2. SEKWENCYJNY ALGORYTM EWOLUCYJNY SAE

W podejściu tym algorytm ewolucyjny wykorzystany jest do optymalizacji obciążeń jednostek w jednej chwili t (godzinie) okresu T . Uruchamiając AE sekwencyjnie dla każdej chwili $t = 1, 2, \dots, T$, otrzymuje się harmonogram pracy jednostek w okresie T . Przy ocenie rozwiązań uwzględnia się, oprócz kosztów zmiennych, koszty rozruchu związane z decyzją o odstawieniu jednostki pracującej w chwili $(t - 1)$ lub uruchomieniu jednostki odstawionej w chwili $(t - 1)$. Czasy postojów jednostek uruchamianych w chwili t są znane – wynikają ze stanu początkowego t_{psi} oraz z wcześniejszych realizacji ERO dla chwil poprzedzających

chwile t . Czasy postojów jednostek odstawianych są niewiadome. Ponieważ JW nie może być odstawiona na czas krótszy od jej minimalnego czasu postoju $t_{p\min i}$, przyjęto wstępnie, że z decyzją o odstawieniu jednostki i -tej związane są koszty jej rozruchu po czasie postoju $t_{pxi} = t_{p\min i}$ i koszty te dolicza się do kosztów zmiennych wynikających z obciążenia jednostek oraz kosztów rozruchu jednostek uruchamianych w chwili t . Stąd funkcja kosztu, stosowana do oceny rozwiązań w AE optymalizującym obciążenia JW w chwili t , przybiera postać:

$$F_{p1}(t) = \sum_{i=1}^N \left\{ \alpha_i(t) K_{zi} [P_{ni}(t)] \Delta t + \alpha_i(t) [1 - \alpha_i(t-1)] K_{ri}(t_{pi}) + [1 - \alpha_i(t)] \alpha_i(t-1) K_{ri}(t_{pxi}) \right\} \quad (4.150)$$

oznaczenia jak we wzorze (4.2).

Wartości funkcji binarnych $\alpha_i(t)$ wynikają z wartości genów (wzór (4.136)).

Dla potrzeb symulacji populację startową (dla $t = 1$) utworzono w sposób losowy; w rzeczywistości warunki startowe określone są obciążeniami JW w godzinie poprzedzającej okres optymalizacji T . Populacje startowe dla kolejnych iteracji $t = 2, 3, \dots, T$ pokrywają się z populacjami końcowymi z iteracji poprzedzających.

Liczba punktów N_p przestrzeni rozwiązań dla jednej chwili t zależy od dokładności δ_p z jaką określa się obciążenia jednostek:

$$N_p = \prod_{i=1}^N \left[\frac{1}{\delta_p} (P_{n\max i} - P_{n\min i}) + 2 \right] \quad (4.151)$$

Przykładowo dla $\delta_p = 1$ MW, $N = 12$, $P_{n\min i} = 180$ MW, $P_{n\max i} = 350$ MW liczba ta jest rzędu 10^{26} .

4.5.2.1. REPREZENTACJA ZMIENNYCH

Zastosowano reprezentację zmiennopozycyjną; geny z_i kodują obciążenia poszczególnych jednostek $i = 1, 2, \dots, N$. Zakres zmienności genów określony jest podobnie jak w KAE (4.134). Tablica 4.16 obrazuje sposób kodowania.

Tablica 4.16. Sposób kodowania w sekwencyjnym algorytmie ewolucyjnym stosowanym do ERO-z. Źródło: opracowanie własne.

Postać chromosomu:	z_1	z_2	z_3	z_4	...	z_N
Przykładowy chromosom:	211,...	192,...	0	328,...	...	254,...
Znaczenie genów:	P_{n1}	P_{n2}	P_{n3}	P_{n4}	...	P_{nN}

gdzie: z_i – liczba rzeczywista reprezentująca obciążenie jednostki i -tej.

Dla liczby jednostek $N = 12$ chromosom składa się z 12 genów.

4.5.2.2. OPERATORY GENETYCZNE. METODY ELIMINACJI OGRANICZEŃ FUNKCJI KOSZTU

Do eksploracji przestrzeni stanów jednostek proponuje się operator mutacji MZR, analogiczny do operatora mutacji binarnej równomiernej MBR. W wyniku mutacji wybrany losowo gen z_i zmienia wartość wg reguły:

$$z_i' = \begin{cases} r_r \in \langle P_{n\min i}, P_{n\max i} \rangle, & \text{jeśli } z_i = 0 \\ 0, & \text{jeśli } z_i \neq 0 \end{cases} \quad (4.152)$$

gdzie: r_r – losowa liczba rzeczywista o rozkładzie jednostajnym.

Mutację MZR realizuje funkcja MUTACJA_ZR.m.

Przestrzeń obciążeń jednostek przeszukuje operator mutacji nierównomiernej MZN opisany w podrozdziale 4.5.1.2. Wartości zmutowanych genów otrzymuje się ze wzoru (4.138), przy czym $z_i(t)$ należy w nim zamienić na z_i . Mutację MZN dla algorytmu sekwencyjnego zaimplementowano w funkcji MUTACJA_ZN2.m.

Jako metodę krzyżowania zastosowano krzyżowanie jednopunktowe z miejscami cięć między genami.

Osobnikom, które nie spełniają ograniczeń zakresu generacji grupy jednostek (4.7) i (4.8) lub minimalnych dopuszczalnych czasów postoju i pracy po rozruchu (4.9) i (4.10), przypisuje się stały koszt K_x , większy od przewidywanego, maksymalnego kosztu osobników dopuszczalnych względem tych ograniczeń. Osobniki spełniające te ograniczenia, a naruszające warunek bilansu mocy (4.5) naprawiane są wg algorytmu naprawy z kryterium przyrostów względnych kosztów zmiennych SN2, przedstawionego w podrozdziale 4.5.1.3. Po naprawie koszt tych osobników wyznacza się z funkcji (4.150).

4.5.2.3. SCHEMAT ALGORYTMU OPTIMALIZACYJNEGO

Algorytm ewolucyjny sekwencyjny do ERO-z na poziomie elektrowni przedstawiono poniżej:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P_z(t)$ i poziomu rezerwy wirującej $P_{rw}(t)$, wartości granicznych obciążeń jednostek $P_{n\min i}$ i $P_{n\max i}$, charakterystyk: kosztów zmiennych $K_{zi}(P_{ni})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie $t_{p\min i}$ i minimalnych czasów pracy po rozruchu $t_{r\min i}$.
2. Określenie parametrów i ustawień algorytmu ewolucyjnego: liczby generacji L_{gen} , liczebności populacji L_{pop} , populacji początkowej \mathcal{P} , parametrów mutacji, prawdopodobieństwa krzyżowania p_k , warunku zatrzymania.
3. Dla $t = 1$ do T powtarzaj:
 - 3.1. Dla $l_{gen} = 1$ do L_{gen} lub do momentu spełnienia warunku zatrzymania powtarzaj:
 - 3.1.1. Jeśli $l_{gen} \neq 1$, włączenie do populacji $\mathcal{P}_{l_{gen}}$ najlepszego osobnika rodzicielskiego z populacji $\mathcal{P}_{(l_{gen}-1)}$.

3.1.2. Ocena populacji $\mathcal{P}_{t_{gen}}$:

3.1.2.1. Przypisanie kosztu K_x osobnikom nie spełniającym ograniczeń związanych z zakresem generacji grupy jednostek (4.7) i (4.8) lub z minimalnym czasem postoju (4.9) i pracy (4.10).

3.1.2.2. Naprawa osobników dopuszczalnych ze względu na warunki (4.7) ÷ (4.10), a nie spełniających warunku bilansu mocy (4.5) w chwili t . Wyznaczenie kosztów zmiennych, kosztów rozruchów i wartości funkcji kosztu (4.150) dla osobników naprawionych.

3.1.2.3. Wymiana osobników naruszających warunek (4.5) na ich naprawione wersje z prawdopodobieństwem p_w .

3.1.3. Sprawdzenie warunku zatrzymania.

3.1.4. Selekcja turniejowa.

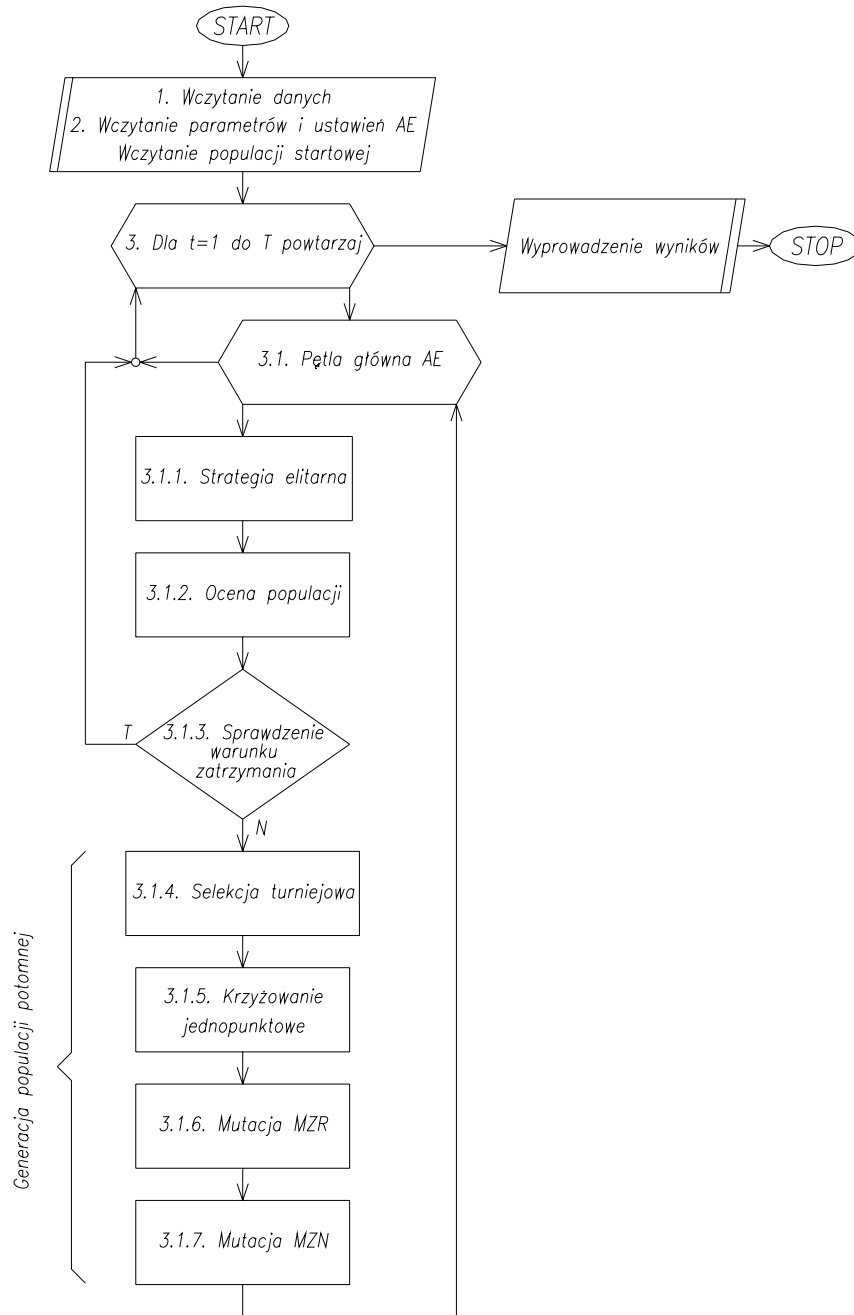
3.1.5. Krzyżowanie jednopunktowe.

3.1.6. Mutacja MZR.

3.1.7. Mutacja MZN.

3.2. $\mathcal{P}_1 = \mathcal{P}_{t_{gen}}$.

Schemat blokowy tego algorytmu zaprezentowano na rys. 4.32.



Rys. 4.32. Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą sekwencyjnego algorytmu ewolucyjnego. Źródło: opracowanie własne.

4.5.3. OBLICZENIA OPTIMALIZACYJNE EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ NA POZIOMIE ELEKTROWNI

Wykorzystując zdefiniowane powyżej algorytmy ewolucyjne wykonano obliczenia optymalizacyjne dla zadania ekonomicznego rozdziału obciążeń na poziomie elektrowni, określonego w podrozdziale 4.1. Algorytmy uruchamiano 10-krotnie z różnych utworzonych losowo populacji startowych. Działania algorytmów oceniano za pomocą następujących wskaźników :

- minimalnej (F_{Pmin}), maksymalnej (F_{Pmax}) i średniej (\bar{F}_P) wartość kosztu najlepszych rozwiązań znalezionych przez algorytm w 10-ciu uruchomieniach oraz odchylenia standardowego kosztu tych rozwiązań σ_{F_p} ;
- całkowity czas działania algorytmu – t_{alg} .

Wyniki zestawiono w tabelicy 4.17.

Parametry i ustawienia kompleksowego AE:

- liczba generacji – $L_{gen} = 10\ 000$,
- liczebność populacji – $L_{pop} = 400$,
- prawdopodobieństwo krzyżowania – $p_k = 0,9$,
- oczekiwana liczba mutacji typu MZ1 chromosomu – $w_{m1} = 0,5$,
- oczekiwana liczba mutacji typu MZN chromosomu – $w_{m2} = 0,5$,
- oczekiwana liczba transpozycji chromosomu – $w_t = 0,25$,
- prawdopodobieństwo wymiany osobników niedopuszczalnych w strategii naprawy – $p_w = 1$,
- parametr sterujący naporem selekcyjnym w strategii naprawy z kryterium jednostkowych kosztów zmiennych – $m_r = 3$,
- rozmiar turnieju w selekcji turniejowej – $r_t = 2$,
- parametry mutacji MZ1 – $a_{zj1} = a_{oj1} = 0$, $a_{zj2} = 0,8$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$.

Parametry i ustawienia sekwencyjnego AE:

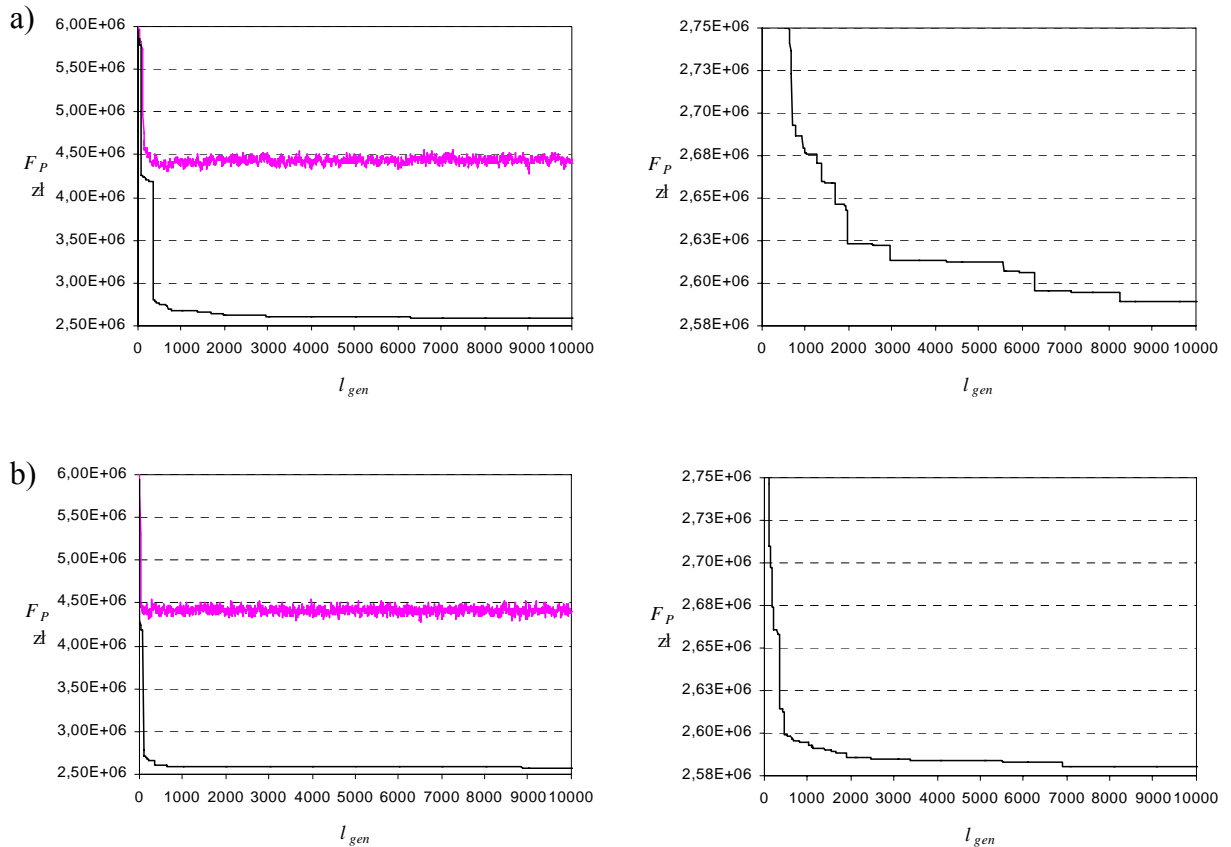
- liczba generacji – $L_{gen} = 50$,
- liczebność populacji – $L_{pop} = 50$,
- prawdopodobieństwo krzyżowania – $p_k = 0,9$,
- oczekiwana liczba mutacji typu MZR chromosomu – $w_{m1} = 0,5$,
- oczekiwana liczba mutacji typu MZN chromosomu – $w_{m2} = 0,5$,
- prawdopodobieństwo wymiany osobników niedopuszczalnych w strategii naprawy – $p_w = 1$,
- rozmiar turnieju w selekcji turniejowej – $r_t = 2$,
- stały koszt osobników nie spełniających ograniczeń (4.7), (4.8), (4.9) lub (4.10) – $K_x = 10^6$.

Tablica 4.17. Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-z na poziomie elektrowni. Źródło: opracowanie własne.

L.p.	Wariant algorytmu	F_{Pmin} zł	F_{Pmax} zł	\bar{F}_P zł	σ_{F_p} zł	t_{alg} h
1.	KAE+SN1	2 589 468	2 609 241	2 599 324	7071	29,78
2.	KAE+SN2	2 580 310	2 588 571	2 582 298	2256	25,65
3.	SAE+SN2	2 580 848	2 580 848	2 580 848	0	0,32


gdzie: KAE – kompleksowy algorytm ewolucyjny; SAE – sekwencyjny algorytm ewolucyjny; SN1 – strategia naprawy z kryterium jednostkowych kosztów zmiennych; SN2 – strategia naprawy z kryterium przerostów względnych kosztów zmiennych.

Na rys. 4.33 i 4.34 zamieszczono przebiegi procesów ewolucyjnych. Harmonogramy pracy JW o najmniejszych kosztach, znalezione przez testowane algorytmy, przedstawiono na rys. 4.35.




Rys. 4.33. Średnia wartość funkcji kosztu populacji (wykres górny) oraz koszt najlepszego osobnika (wykres dolny) w kolejnych generacjach algorytmu: a) KAE+SN1, b) KAE+SN2.

Źródło: opracowanie własne.



Rys. 4.34. Koszt (4.150) najlepszego osobnika w generacjach algorytmu SAE+SN2 dla kolejnych godzin t okresu optymalizacji T . Źródło: opracowanie własne.



Rys. 4.35. Harmonogramy pracy jednostek wytwórczych otrzymane przy użyciu algorytmów: a) KAE+SN1, b) KAE+SN2, c) SAE+SN2. Źródło: opracowanie własne.

W celu sprawdzenia efektywności SAE wykonano obliczenia porównawcze przeliczając wszystkie możliwe rozwiązania (przyjmując $\delta_P = 1$ MW). Wymagało to okrojania zadania do trzech jednostek wytwórczych; podobnie jak w podrozdziale 4.4.4 przyjęto: $N = 3$ (bloki nr 1, 2 i 3), przebieg zapotrzebowania $P'_z(t) = P_z(t)/4$, poziom rezerwy $P'_{rw}(t) = 0,05P'_{z\max}$ i stan początkowy $t_{ps} = [-24, -24, -24]$. Obliczenia dla przeglądu zupełnego wykonano korzystając z programu [Brz02], zmodyfikowanego przez autora rozprawy i skompilowanego w środowisku programistycznym Delphi (dodatek 8 – EROKOMPL2.pas). Sekwencyjny przegląd zupełny zrealizowano wg algorytmu przedstawionego poniżej:

1. Wczytanie danych: okresu optymalizacji T , przebiegu zapotrzebowania $P'_z(t)$ i poziomu rezerwy wirującej $P'_{rw}(t)$, wartości granicznych obciążeń jednostek $P_{n\min i}$ i $P_{n\max i}$, charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$ i kosztów rozruchów $K_{ri}(t_p)$ jednostek, stanów początkowych jednostek t_{psi} , minimalnych czasów postoju jednostek w rezerwie $t_{p\min i}$ i minimalnych czasów pracy po rozruchu $t_{r\min i}$.
2. Dla $t = 1$ do T powtarzaj:
 - 2.1. Dla $P_{n1} = \{0, P_{n\min 1}, P_{n\min 1} + 1, \dots, P_{n\max 1}\}$ powtarzaj:
 - 2.1.1. Dla $P_{n2} = \{0, P_{n\min 2}, P_{n\min 2} + 1, \dots, P_{n\max 2}\}$ powtarzaj:
 - 2.1.1.1. Dla $P_{n3} = \{0, P_{n\min 3}, P_{n\min 3} + 1, \dots, P_{n\max 3}\}$ powtarzaj:

2.1.1.1.1. Jeśli spełniony jest warunek bilansu mocy:

$$|P_{n1} + P_{n2} + P_{n3} - P'_z(t)| \leq \delta_p = 1 \text{ wykonaj:}$$

2.1.1.1.1.1. Jeśli spełnione są warunki generacji grupy jednostek (4.7) i (4.8) oraz warunki minimalnego czasu postoju (4.9) i pracy (4.10), oblicz składniki funkcji kosztu (4.150): koszty zmienne pracy jednostek przy obciążeniach P_{n1} , P_{n2} , P_{n3} oraz koszty rozruchów i odstawień.

2.1.1.1.1.2. Zapamiętaj P_{n1} , P_{n2} , P_{n3} jeśli otrzymane dla godziny t rozwiązanie jest lepsze od dotychczasowych.

Z przeliczenia wszystkich możliwych rozwiązań otrzymano rozwiązanie optymalne (wg kryterium (4.150)), które z dokładnością do jedności pokrywa się z rozwiązaniem zamieszczonym w tablicy D6.1 (dodatek 6), otrzymanym z obliczeń optymalizacyjnych z wykorzystaniem algorytmów ERO-k. Identyczny rezultat otrzymano wykonując obliczenia porównawcze za pomocą SAE.

W algorytmie przeglądu zupełnego, aby dojść do rozwiązania optymalnego, należy sprawdzić dla każdej godziny t wszystkie punkty ze zdyskretyzowanej przestrzeni rozwiązań, tj. $24N_p = 24(350 - 180 + 2)^3 = 122\ 122\ 752$ punktów, przy liczbie odwołań do funkcji kosztu równej 447 884 (w przypadku rozwiązań nie spełniających bilansu mocy nie obliczano funkcji kosztu). W obliczeniach za pomocą SAE liczba punktów sprawdzanych dla każdej godziny t wynosi $L_{gen}L_{pop}$. Przyjęto stałą liczbę generacji $L_{gen} = 20$, a licznosc populacji wyznaczono eksperymentalnie. Najmniejsza licznosc populacji, dla której 30-krotnie otrzymano rozwiązanie optymalne, wyniosła $L_{pop} = 8$. Stąd liczba sprawdzonych przez SAE punktów – 3840, a liczba odwołań do funkcji kosztu (wyznaczona eksperymentalnie) ok. 2200.

Wnioski

1. Kompleksowy algorytm ewolucyjny ze strategią naprawy wg kryterium przyrostów względnych kosztów zmiennych SN2 znalazł najlepsze rozwiązanie spośród testowanych algorytmów optymalizacyjnych dla ERO-z. Koszt tego rozwiązania różnił się od kosztu rozwiązania P_{nopt} o $\Delta F_{P_{min}\%} = 0,020\%$ (507 zł). Proces ewolucyjny był szybciej zbieżny od procesu w KAE z kryterium SN1.
2. SAE optymalizuje obciążenia JW dla poszczególnych godzin okresu T , uwzględniając w ocenie rozwiązań również koszty decyzji o odstawieniach lub rozruchach jednostek. O odstawieniu jednostki w godzinie t decyduje różnica kosztów zmiennych jej pracy w godzinie t , kosztów zmiennych związanych z przejściem obciążenia tej jednostki przez pozostałe jednostki oraz kosztów jej rozruchu po czasie postoju t_{pxi} . Przy podejmowaniu tej decyzji nie uwzględnia się przebiegu zapotrzebowania w godzinach następnych. Może dojść do sytuacji, że mimo wzrostu zapotrzebowania jednostka zostanie odstawiona. Dobór kosztu związanego z odstawieniem JW jest sprawą dyskusyjną. Pominięcie tego

kosztu prowadzi jednak do niewłaściwego działania algorytmu, który odstawia JW, jeśli tylko spowoduje to zmniejszenie kosztu zmiennego rozwiązania. Oznacza to, że zawsze pracuje minimalna liczba jednostek niezbędnych do pokrycia zapotrzebowania (koszt takiego rozwiązania wynosi $K_c = 2\ 666\ 060$).

SAE może być wykorzystany do generacji populacji startowej (dopuszczalnej względem wszystkich ograniczeń) przetwarzanej następnie w kompleksowym algorytmie ewolucyjnym. Aby otrzymać zróżnicowaną populację startową, koszty odstawień t_{pxi} w funkcji kosztu (4.150) mogą przyjmować różne wartości.

Przebieg procesu ewolucyjnego w SAE jest następujący (rys. 4.34): dla godziny $t = 1$, w początkowych generacjach znajdowane są rozwiązania dopuszczalne, które szybko zbiegają się do optymalnego względem kryterium (4.150). Populacja zwrócona przez algorytm dla $t = 1$ staje się populacją startową dla $t = 2$. Populacja ta zawiera wiele dopuszczalnych względem warunków (4.7) ÷ (4.10) osobników, które podlegają naprawie. Już w pierwszych generacjach znajdowane jest rozwiązanie optymalne dla godziny $t = 2$. Dla kolejnych godzin proces przebiega podobnie, jak dla godziny $t = 2$.

3. Kompleksowy algorytm ewolucyjny ze strategią naprawy wg kryterium jednostkowych kosztów zmiennych wykazał najgorsze działanie. Najlepsze rozwiązanie znalezione przez ten algorytm było gorsze od rozwiązania P_{nopt} o $\Delta F_{P_{min}\%} = 0,37\%$ tj. 9665 zł. Oznacza to, że proponowane kryterium jednostkowych kosztów zmiennych, pomimo swego losowo – deterministycznego charakteru, nie jest właściwe dla ERO-z.
4. Sekwencyjny algorytm ewolucyjny działał znacznie szybciej od algorytmu kompleksowego oraz od algorytmów optymalizacyjnych proponowanych dla zadania ERO-k. KAE, z uwagi na rozległą przestrzeń przeszukiwań, wymagał znacznie większej liczby odwołań do funkcji kosztu i czasu obliczeń ponad 20 h.
5. W celu wykazania efektywności SAE, dla zadania uproszczonego przeliczono wszystkie możliwe rozwiązania. Otrzymano w ten sposób rozwiązanie optymalne globalnie względem kryterium (4.150). SAE pozwalał uzyskać takie rozwiązanie przy znacznie mniejszej (ok. 200-krotnie) liczbie odwołań do funkcji kosztu, sprawdzając tylko 3840 punktów z przestrzeni rozwiązań obejmującej ponad 122 mln punktów. Przeliczenie wszystkich punktów dla KAE, z uwagi na rozmiary zadania (4.135), jest nierealne, nawet dla zadania okrojonego do trzech JW.

4.6. ANALIZA DOKŁADNOŚCI PROPONOWANYCH MODELI OPTYMALIZACYJNYCH

Wartości funkcji kryterialnych (funkcji kosztów) we wszystkich proponowanych algorytmach optymalizacyjnych obciążone są błędami zależnymi od następujących czynników:

- błędów określenia charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$,
- błędów określenia charakterystyk przyrostów względnych kosztów zmiennych $\varepsilon_{ki}(P_{ni})$,
- błędów określenia charakterystyk kosztów rozruchów $K_{ri}(t_{pi})$,
- błędów prognozy zapotrzebowania $P_z(t)$,
- dopuszczalnego błędu niezbilansowania – δ_p (4.13), (4.140).

Celem przeprowadzonej analizy błędów jest próba odpowiedzi na pytania:

1. Jakie straty materialne ponosi się w wyniku błędów parametrów wejściowych modeli optymalizacyjnych wymienionych powyżej.
2. W jaki sposób błędy parametrów wejściowych modeli wpływają na błędy funkcji kosztów i, w efekcie, na błędy określania obciążeń JW.

Wstępnie zakłada się:

1. Maksymalne (graniczne) błędy względne, wyrażone w procentach, z jakimi określa się charakterystyki kosztowe JW wynoszą:
 - dla charakterystyk kosztów zmiennych $K_{zi}(P_{ni}) - \delta_{grKzi}\%$,
 - dla charakterystyk przyrostów względnych kosztów zmiennych $\varepsilon_{ki}(P_{ni}) - \delta_{gr\varepsilon}\%$,
 - dla charakterystyk kosztów rozruchów $K_{ri}(t_{pi}) - \delta_{grKri}\%$.
2. Błędy określania charakterystyk kosztowych mają zerową wartość średnią i rozkłady normalne lub zbliżone do normalnych.
3. Średni absolutny względny błąd procentowy prognozy zapotrzebowania P_z wynosi $\bar{\delta}_{absPz}\%$.
4. Błędy $\delta_{Pz\%}(t)$ jakimi obciążona jest prognoza zapotrzebowania mają zerową wartość średnią i rozkłady normalne lub zbliżone do normalnych.
5. Dopuszczalny błąd niezbilansowania δ_p jest bliski zera.
6. Charakterystyki i prognozę obciążone błędami: $\widehat{K}_{zi}(P_{ni})$, $\widehat{K}_{ri}(t_{pi})$, $\widehat{\varepsilon}_{ki}(P_{ni})$ oraz $\widehat{P}_z(t)$ otrzymuje się dodając do danych charakterystyk $K_{zi}(P_{ni})$, $K_{ri}(t_{pi})$, $\varepsilon_{ki}(P_{ni})$ i prognozy $P_z(t)$ błędy generowane symulacyjnie zgodnie z ich rozkładami.

Na dokładność określenia charakterystyk kosztowych opisujących JW wpływają dwa rodzaje błędów: błędy pomiarowe poszczególnych wielkości niezbędnych do sporządzenia tych charakterystyk oraz błędy aproksymacji. Zgodnie z wymogami norm dotyczących pomiarów i badań urządzeń w elektrowni (np. [PN-72]), błędy systematyczne pomiarów powinny być wyeliminowane, np. poprzez stosowanie poprawek. Błędy przypadkowe można traktować jako zmienne losowe, które podlegają rozkładowi normalnemu o zerowej wartości oczekiwanej [Sza86], [Bra98], stąd założenie 2. Dokładność aproksymacji charakterystyk

kosztowych JW, analizowana w podrozdziałach 4.3.3 i 4.3.4, jest znacznie większa od dokładności pomiarów. Parametry rozkładów błędów oraz przedziały ufności są najczęściej nieznanne. Podawany jest jedynie średni błąd względny graniczny, wynikający z błędów pomiarów i badań poszczególnych wielkości, na bazie których konstruuje się charakterystyki. Błąd ten może być określany dla różnych poziomów ufności [Łac91]. Za [Brz73] przyjęto, że wartość 2σ definiuje poziom ufności ($1 - \alpha = 0,95$), dla którego wyznacza się błędy graniczne. Wobec tego odchylenie standardowe błędów określania charakterystyk kosztowych wynosi:

$$\sigma_{\delta x} = \frac{\delta_{grx\%}}{2} \quad (4.153)$$

gdzie: x – oznaczenie wielkości, $x = \{K_{zi}, K_{ri}, \varepsilon_i\}$; $\delta_{grx\%}$ – procentowy graniczny błąd względny określania charakterystyki kosztowej.

W praktyce charakterystyki kosztów zmiennych oraz przyrostów względnych strumienia kosztów zmiennych sporządzane są na podstawie tych samych danych pomiarowych, wobec czego błędy ich określania są ściśle od siebie zależne. Obciążenia jednostek w klasycznej metodzie ERO odczytuje się z charakterystyki odwrotnej do charakterystyki przyrostów względnych $P_n(\varepsilon_k)$, zdefiniowanej wzorem (4.45). Jeśli charakterystyka $\varepsilon_k(P_n)$ obciążona jest błędem $\delta_{\varepsilon\%}$, charakterystyka do niej odwrotna przyjmuje postać:

$$P_n(\varepsilon_k) = \begin{cases} P_{n\min}, & \text{dla } \varepsilon_k < \varepsilon_k(P_{n\min}) \\ P_{n\max}, & \text{dla } \varepsilon_k > \varepsilon_k(P_{n\max}) \\ \frac{\varepsilon_k}{\frac{1 + \delta_{\varepsilon\%}}{100}} - w_b, & \text{dla } \varepsilon_k(P_{n\min}) \leq \varepsilon_k \leq \varepsilon_k(P_{n\max}) \end{cases} \quad (4.154)$$

Dokładność prognoz krótkoterminowych, jak wynika z przeglądu literatury prognostycznej, definiują często absolutne względne błędy procentowe (*absolute percentage errors - APE*):

$$\delta_{absPz\%}(t) = 100 \left| \frac{\widehat{P}_z(t) - P_z(t)}{P_z(t)} \right| \quad (4.155)$$

gdzie: $\widehat{P}_z(t), P_z(t)$ – wartość prognozowana i rzeczywista zapotrzebowania w chwili t .

Podstawą oszacowania błędów prognoz (generowanych przez konkretne modele prognostyczne) stanowią błędy obliczone po wygaśnięciu prognoz. Zwykle wraz z prognozą

dostarczane są informacje o uśrednionym błędzie prognozy przebiegu dobowego $\bar{\delta}_{absPz\%} = \text{mean}[\delta_{absPz\%}(t)]$, gdzie $\text{mean}(\cdot)$ – operator wartości średniej. Rzadziej podaje się błędy średnie prognoz zapotrzebowania na poszczególne chwile t . Wedle przesłanek literaturowych rozkłady względnych procentowych błędów:

$$\delta_{Pz\%}(t) = \text{mean} \left[100 \frac{\widehat{P}_z(t) - P_z(t)}{P_z(t)} \right] \quad (4.156)$$

prognoz krótkoterminowych wykazują podobieństwo do rozkładu normalnego [Łyp99]. Aby odpowiedzieć na pytanie – jaka jest wartość odchylenia standardowego $\sigma_{\delta Pz}$ błędów $\delta_{Pz\%}(t)$ prognozy zapotrzebowania, jeśli średni absolutny względny błąd procentowy tej prognozy wynosi $\bar{\delta}_{absPz\%}$ – przeprowadzono symulację komputerową wg następującego algorytmu:

1. Przyjmij wartości n oraz P_z .
2. Dla różnych wartości $\sigma_{\delta Pz}$ powtarzaj:
 - 2.1. Wygeneruj n błędów $\delta_{Pz\%j}$ ($j = 1, 2, \dots, n$) o rozkładzie $\text{nor}(0, \sigma_{\delta Pz})$.
 - 2.2. Wyznacz wartości n prognoz $\widehat{P}_{zj} = P_z \left(1 + \frac{\delta_{Pz\%j}}{100} \right)$, $j = 1, 2, \dots, n$.
 - 2.3. Wyznacz błąd $\bar{\delta}_{absPz\%}(\sigma_{\delta Pz}) = \frac{100}{n} \sum_{j=1}^n \left| \frac{\widehat{P}_{zj} - P_z}{P_z} \right|$.

gdzie $\text{nor}(a, b)$ – wartość liczbową losowaną z rozkładu normalnego o średniej a i odchyleniu standardowym b .

Dla różnych wartości $\sigma_{\delta Pz}$ i P_z oraz dla $n = 1\,000\,000$, stosunek $\frac{\bar{\delta}_{absPz\%}(\sigma_{\delta Pz})}{100\sigma_{\delta Pz}}$ był stały i zawierał się w granicach $0,796 \div 0,800$, stąd przyjęto

$$\sigma_{\delta Pz} = \frac{\bar{\delta}_{absPz\%}}{0,8} \quad (4.157)$$

Poziom ufności dla wartości $0,8\sigma$ wynosi 0,58, co oznacza, że w 58 przypadkach na 100 błąd prognozy będzie mniejszy od $\bar{\delta}_{absPz\%}$. Dysponując błędem $\bar{\delta}_{absPz\%}$ można wyliczyć graniczny (przy poziomie ufności 0,95) absolutny względny błąd prognozy:

$$\delta_{grPz\%} = 2\sigma_{\delta Pz} = 2,5\bar{\delta}_{absPz\%} \quad (4.158)$$

Operator systemu (Krajowa Dyspozycja Mocy) może narzucić granicę dopuszczalnego błędu prognozy zapotrzebowania dla całego SEE [Dob91]:

$$\forall t: \Delta_{P_{zs}}(t) = |\widehat{P}_{zs}(t) - P_{zs}(t)| \leq \Delta_{grP_{zs}} \quad (4.159)$$

gdzie: $\Delta_{P_{zs}}(t)$ – absolutny błąd prognozy zapotrzebowania w chwili t dla całego SEE, MW;
 $\Delta_{grP_{zs}}$ – graniczny absolutny błąd prognozy zapotrzebowania dla całego SEE, MW;
 $\widehat{P}_{zs}(t), P_{zs}(t)$ – prognoza i wartość rzeczywista zapotrzebowania dla całego SEE w chwili t .
 Błąd graniczny jakim obciążony jest przebieg zapotrzebowania przydzielonego elektrowni wnosi:

$$\Delta_{grP_{ze}}(t) = \Delta_{grP_{zs}} \frac{P_z(t)}{P_{zs}(t)} \quad (4.160)$$

Jeśli założyć, że błąd graniczny określa się dla poziomu ufności 0,95 (2σ), otrzymujemy wzór na odchylenia standardowe błędów prognozy zapotrzebowania przydzielonego elektrowni:

$$\sigma_{\delta P_z}(t) = 100 \frac{\Delta_{grP_{ze}}(t)}{2P_z(t)} = 100 \frac{\Delta_{grP_{zs}}}{2P_{zs}(t)} \quad (4.161)$$

Modelowanie statystyczne rozkładu dodatkowych kosztów spowodowanych błędami parametrów wejściowych modeli optymalizacyjnych

W wyniku obliczeń optymalizacyjnych, przy obarczonych błędami charakterystykach i prognozie, otrzymuje się rozwiązanie quasi-optymalne \widehat{P}_{nopt} , które reprezentuje harmonogramy pracy JW oraz ich obciążenia. W warunkach bez błędów parametrów, rozwiązanie to może nie spełniać ograniczeń generacji grupy jednostek (4.7), (4.8) oraz warunku bilansu mocy (4.5). W przełożeniu na język praktyki, przypadek niedotrzymania ograniczeń generacji oznacza, że zaplanowane do pracy jednostki w trakcie realizacji planu nie są w stanie pokryć zapotrzebowania, które znacznie odbiega od prognozowanego. Wymaga to uruchomienia dodatkowych JW o szybkim rozruchu (zwykle znacznie droższych), wyłączenia odbiorów lub odstawienia jednostek pracujących, co pociąga za sobą zwiększenie kosztów i korektę planu. Przypadek naruszenia bilansu mocy jest nie do uniknięcia; obciążenia JW są wtedy korygowane na bieżąco (regulatorem ARCM), przy nie zmienionych harmonogramach. Otrzymujemy w ten sposób rozwiązanie skorygowane \widehat{P}'_{nopt} . Możliwy jest także przypadek przeprowadzania obliczeń optymalizacyjnych już w trakcie realizacji planu (dysponuje się wtedy dokładniejszymi prognozami) i korekty harmonogramów, ale ten wariant nie będzie tutaj analizowany. Dodatkowe koszty wynikają więc z dwóch źródeł:

- planowane harmonogramy pracy JW są niedopuszczalne i wymagają korekty,
- planowane harmonogramy są dopuszczalne (ale niekoniecznie optymalne), korekty wymagają jedynie obciążenia JW.

Jeśli, w tym drugim przypadku, planowane harmonogramy są optymalne, a obciążenia korygowane są wg kryterium ERO, otrzymujemy rozwiązanie o najniższym koszcie. Jeśli harmonogramy te odbiegają od optymalnych, pojawiają się dodatkowe koszty związane z rozdziałem obciążenia na mniejszą lub większą od optymalnej liczbę bloków.

Rozkład dodatkowych kosztów spowodowanych błędami parametrów modeli optymalizacyjnych wyznaczono za pomocą modelowania statystycznego – metodą Monte Carlo. Zmiennymi losowymi są w tym przypadku błędy jakimi obciążone są charakterystyki kosztowe – $\delta_{K_{zi}\%}$, $\delta_{K_{ri}\%}$ i $\delta_{\varepsilon_i\%}$, oraz prognoza zapotrzebowania – $\delta_{P_z\%}(t)$. Błędy $\delta_{K_{zi}\%}$ oraz $\delta_{\varepsilon_i\%}$ ($\forall i$) związane są zależnością, której formuła zależy od metodyki sporządzania obu charakterystyk. Poza tym wyjątkiem zmienne losowe są niezależne. Metoda polega na losowym generowaniu błędów (zgodnie z ich rozkładami), obciążaniu tymi błędami charakterystyk kosztowych oraz prognozy zapotrzebowania i przeprowadzeniu obliczeń optymalizacyjnych. W wyniku otrzymuje się rozwiązanie optymalne (lub bliskie optymalnemu) dla zakłóconych parametrów modelu i, znając rozwiązanie optymalne w warunkach bez błędów parametrów, wylicza się dodatkowe koszty spowodowane tymi błędami. Wielokrotne powtarzanie takich obliczeń umożliwia wyznaczenie empirycznego rozkładu prawdopodobieństwa tych dodatkowych kosztów i daje odpowiedź na pytania: w ilu przypadkach planowane harmonogramy pracy JW nie różnią się od optymalnych, w ilu przypadkach harmonogramy planowane są niedopuszczalne oraz o ile wzrośnie koszt wytwarzania jeśli harmonogramy są dopuszczalne.

Algorytm Monte Carlo przebiega wg następujących kroków:

1. Wczytanie danych: charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$, kosztów rozruchu $K_{ri}(t_{pi})$, przyrostów względnych $\varepsilon_{ki}(P_{ni})$, prognozy zapotrzebowania $P_z(t)$ oraz ustawień modelu optymalizacyjnego.
2. Wczytanie błędów: $\delta_{grK_{zi}\%}$, $\delta_{grK_{ri}\%}$, $\delta_{gr\varepsilon_i\%}$, $\bar{\delta}_{absP_z\%}$ oraz δ_P .
3. Obliczenie odchyłeń standardowych błędów ze wzorów (4.154) oraz (4.157).
4. Obliczenie wartości funkcji kosztu dla rozwiązania optymalnego bez zakłóceń parametrów modelu: $F_P(P_{nopt})$.
5. Dla $k = 1$ do n powtarzaj:
 - 5.1. Generacja błędów:
 - $\forall i: \delta_{K_{zi}\%} = \text{nor}(0, \sigma_{\delta_{K_{zi}\%}})$,
 - $\forall i: \delta_{K_{ri}\%} = \text{nor}(0, \sigma_{\delta_{K_{ri}\%}})$,
 - $\forall i: \delta_{\varepsilon_i\%} = f(\delta_{K_{zi}\%})$,
 - $\forall t: \delta_{P_z\%}(t) = \text{nor}(0, \sigma_{\delta_{P_z\%}})$.
 - 5.2. Obliczenia optymalizacyjne dla modelu z parametrami obciążonymi błędami:
 - $\forall i: \widehat{K}_{zi} = K_{zi}(1 + \delta_{K_{zi}\%}/100)$,
 - $\forall i: \widehat{K}_{ri} = K_{ri}(1 + \delta_{K_{ri}\%}/100)$,
 - $\forall i: \widehat{\varepsilon}_{ki} = \varepsilon_{ki}(1 + \delta_{\varepsilon_i\%}/100)$,
 - $\forall t: \widehat{P}_z(t) = P_z(t)(1 + \delta_{P_z\%}(t)/100)$.

Wynikiem tych obliczeń jest rozwiązanie quasi-optymalne \widehat{P}_{nopt} .

5.3. Korekta rozwiązania \widehat{P}_{nopt} polegająca na ponownym rozdziale obciążeń dla harmonogramów wynikających z \widehat{P}_{nopt} , przy charakterystykach i prognozie bez błędów. Wynikiem jest rozwiązanie \widehat{P}'_{nopt} .

5.4. Obliczenie dodatkowych kosztów względnych spowodowanych błędami parametrów modelu:

$$\delta_{F_{popt}\%} = 100 \frac{F_P(\widehat{P}'_{nopt}) - F_P(\widehat{P}_{nopt})}{F_P(\widehat{P}_{nopt})} \quad (4.162)$$

gdzie: \widehat{P}'_{nopt} – skorygowane rozwiązanie quasi-optymalne; $F_P(\widehat{P}'_{nopt})$ – koszt skorygowanego rozwiązania quasi-optimalnego, wyznaczony przy charakterystykach kosztowych i prognozie bez błędów.

Przykładowe obliczenia wpływu błędów parametrów modeli na dodatkowe koszty wytwarzania wykonano w dwóch wariantach:

1. dla najlepszego algorytmu z grupy ERO-k opisanego w podrozdziale 4.4: AE z reprezentacją binarną czasów odstawień i załączeń RB2, strategią kary, mutacją binarną równomierną MBR, krzyżowaniem jednopunktowym K1P i operatorem transpozycji OT (wariant AE3 z tabeli 4.10),
2. dla sekwencyjnego algorytmu ewolucyjnego.

Obliczeń dla kompleksowego algorytmu ewolucyjnego nie przeprowadzono ze względu na długi czas działania tego algorytmu. Funkcja kosztu dla wariantu 1 określona jest wzorem (4.2), a dla wariantu 2 wzorem (4.150).

Do obliczeń przyjęto następujące dane:

- $\forall i: \delta_{grKzi\%} = \delta_{gr\epsilon i\%} = 4\%$ oraz $\delta_{\epsilon i\%} = \delta_{Kzi\%}$. Wg danych literaturowych [Sza86] błąd metody TKE, którą zastosowano w tym przypadku do konstrukcji charakterystyk energetycznych, na bazie których sporządza się charakterystyki kosztów zmiennych oraz przyrostów względnych kosztów zmiennych, przyjmuje wartości z zakresu 3 ÷ 4%.
- $\forall i: \delta_{grKri\%} = 15\%$. Wg danych literaturowych [Cwy89] łączny błąd pomiaru strat rozruchowych dokonany metodą pośrednią nie przekracza 10%, natomiast metodą bezpośrednią – 8%. W warunkach ruchowych straty rozruchowe są przeciętnie o 20% większe od strat wyznaczonych w warunkach pomiarowych (nominalnych) [Jan92], a w pewnych przypadkach przekraczają je kilkakrotnie.
- $\bar{\delta}_{absPz\%} = 2,5\%$. Wg danych literaturowych [Gro87] i badań prowadzonych przez autora rozprawy [Dud00b], [Józ99] błąd ten kształtuje się w przedziale 2 ÷ 3%.
- $\delta_P = 0,0001$. Analizę wpływu błędu niezbilansowania na wartość funkcji kosztu przeprowadzono w dalszej części tego podrozdziału.

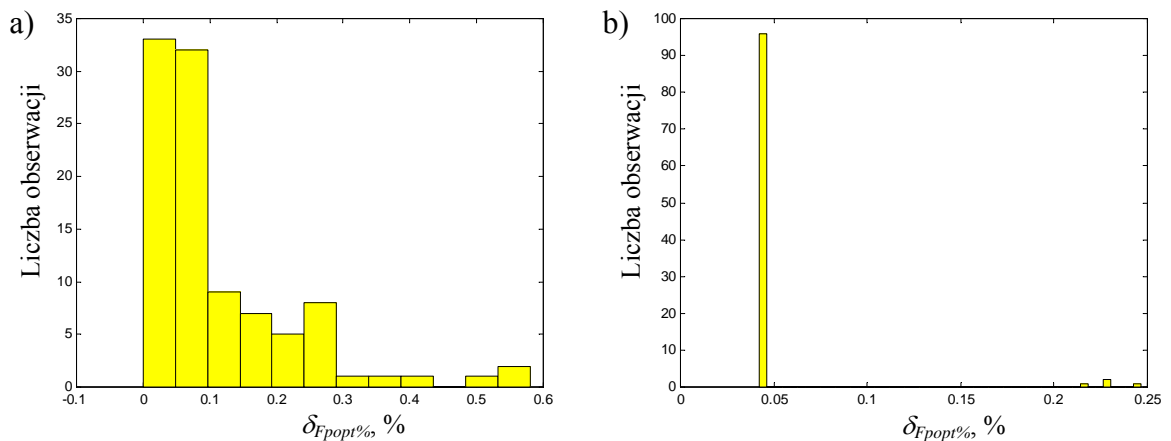
- $n = 100$.

Wyniki symulacji zestawiono w tabeli 4.18, a histogramy względnego wzrostu kosztów wywołanych błędami parametrów modeli pokazano na rys. 4.36.


Tablica 4.18. Wpływ błędów parametrów modeli na wyniki obliczeń optymalizacyjnych. Źródło: opracowanie własne.

Wariant algorytmu	Odsetek rozwiązań z optymalnymi harmonogramami %	Odsetek rozwiązań z harmonogramami niedopuszczalnymi %	$\widehat{\delta}_{F_{popt}\%}$ %	$\widehat{\sigma}_{F_{popt}}$ %
AE3	3	0	0,1142	0,1173
SAE	0	0	0,0505	0,0368

gdzie: $\widehat{\delta}_{F_{popt}\%}$, $\widehat{\sigma}_{F_{popt}}$ – estymowana wartość średnia oraz odchylenie standardowe względnego wzrostu kosztów wytwarzania.



Rys. 4.36. Histogram względnego wzrostu kosztów wytwarzania a) dla AE3, b) dla SAE.



Rys. 4.37. Empiryczna (narysowana grubszą linią) i aproksymowana dystrybuanta kosztów względnych $\delta_{F_{popt}\%}$ dla AE3. Źródło: opracowanie własne.

Rozkład strat $\delta_{F_{popl}\%}$ w modelu AE3 zbliżony jest wizualnie do rozkładu typu gamma lub Weibulla (dopasowano rozkład gamma o parametrach [Dom79]: $a = 1,2711$ i $b = 10,7906$). Empiryczną i teoretyczną (wynikającą z dopasowanego rozkładu gamma) dystrybuantę strat $\delta_{F_{popl}\%}$ dla AE3 pokazano na rys. 4.37). W modelu SAE, w 96% przypadków, otrzymano rozwiązania takie same jak w modelu SAE bez błędów parametrów (rys. 4.35 c) lub zbliżone, różniące się przesunięciem godzin załączeń jednostek nr 2 (z godziny 18 na 17) i 3 (z godziny 17 na 18). Straty powyżej 0,2% otrzymano dla rozwiązań, w których do ruchu załączany był blok nr 1.

Modelowanie statystyczne rozkładów błędów funkcji kosztów i błędów określania obciążeń jednostek wytwórczych spowodowanych błędami parametrów wejściowych modeli optymalizacyjnych

W celu zbadania wpływu błędów parametrów modeli na koszty rozwiązań oraz na błędy określania obciążeń JW, przyjęto harmonogramy h (dopuszczalne) JW i z wykorzystaniem modeli optymalizacyjnych określano optymalne względem tych harmonogramów obciążenia jednostek. Obliczenia wykonano w wariantach bez błędów parametrów (otrzymując rozwiązanie P_{nopt}^h o koszcie $F_P(P_{nopt}^h)$) oraz z błędami parametrów modeli (otrzymując rozwiązanie \hat{P}_{nopt}^h o koszcie $\hat{F}_P(\hat{P}_{nopt}^h)$). Stosując modelowanie statystyczne wyznaczono rozkład błędów względnych funkcji kosztu oraz średnich błędów względnych określania obciążeń JW zdefiniowanych odpowiednio:

$$\delta_{Fp\%} = 100 \frac{\hat{F}_P(\hat{P}_{nopt}^h) - F_P(P_{nopt}^h)}{F_P(P_{nopt}^h)} \quad (4.163)$$

$$\delta_{Pi\%} = 100 \frac{\sum_{i=1}^N \sum_{t=1}^T \frac{\hat{P}_{ni}^h(t) - P_{ni}^h(t)}{P_{ni}^h(t)}}{NT} \quad (4.164)$$

gdzie: $P_{ni}^h(t)$ – obciążenie jednostki i -tej w godzinie t , optymalne względem przyjętych harmonogramów h w warunkach bez błędów parametrów modelu; $\hat{P}_{ni}^h(t)$ – obciążenie jednostki i -tej w godzinie t , optymalne względem przyjętych harmonogramów h w warunkach z błędami parametrów modelu.

W tym przypadku algorytm Monte Carlo ma postać:

1. Wczytanie danych: charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$, kosztów rozruchu $K_{ri}(t_{pi})$, przyrostów względnych kosztów zmiennych $\varepsilon_{ki}(P_{ni})$, prognozy zapotrzebowania $P_z(t)$ oraz zadanych harmonogramów h .
2. Wczytanie błędów: $\delta_{grKzi\%}$, $\delta_{grKri\%}$, $\delta_{gr\varepsilon\%}$, $\bar{\delta}_{absPz\%}$ oraz δ_P .
3. Obliczenie odchyłeń standardowych błędów ze wzorów (4.153) oraz (4.157).

4. Wyznaczenie optymalnego rozwiązania P_{nopt}^h względem harmonogramów h w warunkach bez błędów parametrów.
5. Dla $k = 1$ do n powtarzaj:
- 5.1. Generacja błędów:
- $\forall i: \delta_{Kzi}\% = \text{nor}(0, \sigma_{\delta Kzi})$,
 - $\forall i: \delta_{Kri}\% = \text{nor}(0, \sigma_{\delta Kri})$,
 - $\forall i: \delta_{\varepsilon i}\% = f(\delta_{Kzi}\%)$,
 - $\forall t: \delta_{Pz}\%(t) = \text{nor}(0, \sigma_{\delta Pz})$.
- 5.2. Wyznaczenie optymalnego rozwiązania \hat{P}_{nopt}^h względem harmonogramów h w warunkach, gdy charakterystyki i prognoza obarczone są błędami:
- $\forall i: \hat{K}_{zi} = K_{zi}(1 + \delta_{Kzi}\%/100)$,
 - $\forall i: \hat{K}_{ri} = K_{ri}(1 + \delta_{Kri}\%/100)$,
 - $\forall i: \hat{\varepsilon}_{ki} = \varepsilon_{ki}(1 + \delta_{\varepsilon i}\%/100)$,
 - $\forall t: \hat{P}_z(t) = P_z(t)(1 + \delta_{Pz}\%(t)/100)$.
- 5.3. Obliczenie błędów funkcji kosztu i obciążeń JW wg wzorów (4.163) i (4.164).

Średnia wartość błędu funkcji kosztu $\bar{\delta}_{Fp}\%$ objęta jest przedziałem ufności (dla dużej liczebności próby: $n > 30$):

$$P \left\{ \bar{\delta}_{Fp}\% \in \left(\hat{\delta}_{Fp}\% + u_{\alpha/2} \frac{\hat{\sigma}_{\delta Fp}}{\sqrt{n}}, \hat{\delta}_{Fp}\% + u_{1-\alpha/2} \frac{\hat{\sigma}_{\delta Fp}}{\sqrt{n}} \right) \right\} = 1 - \alpha \quad (4.165)$$

gdzie: $\hat{\delta}_{Fp}\%$ – estymowany z próby błąd średni funkcji kosztu, %; $\hat{\sigma}_{\delta Fp}$ – estymowane z próby odchylenie standardowe błędu funkcji kosztu, %; n – liczność próby (liczba iteracji w p. 5 algorytmu powyżej); α – poziom istotności; $u_{\alpha/2}$, $u_{1-\alpha/2}$ – kwantyle rzędu $\alpha/2$ oraz $(1 - \alpha/2)$ rozkładu normalnego $\text{nor}(0, 1)$.

Przedział ufności zawierający odchylenie standardowe błędów funkcji kosztu $\sigma_{\delta Fp}$ określa wzór:

$$P \left\{ \sigma_{\delta Fp} \in \left(\frac{\hat{\sigma}_{\delta Fp}}{1 + \frac{u_{1-\alpha/2}}{\sqrt{2n}}}, \frac{\hat{\sigma}_{\delta Fp}}{1 + \frac{u_{\alpha/2}}{\sqrt{2n}}} \right) \right\} = 1 - \alpha \quad (4.166)$$

Przykładowe obliczenia wpływu błędów parametrów modelu na błąd funkcji kosztu i błąd określania obciążeń wykonano w trzech wariantach:

1. dla najlepszego algorytmu ERO-k – wariant AE3 z tabeli 4.10,

2. dla kompleksowego algorytmu ewolucyjnego ze strategią naprawy wg przyrostów względnych kosztów zmiennych,
3. dla sekwencyjnego algorytmu ewolucyjnego.


Do obliczeń przyjęto takie same błędy graniczne charakterystyk i średnie prognozy jak w przykładowych obliczeniach wpływu błędów parametrów na dodatkowe koszty wytwarzania oraz $n = 10\ 000$. W wyniku symulacji wyznaczono następujące estymatory, których wartości liczbowe zamieszczono w tabelcy 4.19:

- błąd średni funkcji kosztu: $\widehat{\delta}_{Fp\%}$ i jego przedział ufności przy poziomie ufności 0,95, wyznaczony ze wzoru (4.163): $(g_d(\widehat{\delta}_{Fp\%}), g_g(\widehat{\delta}_{Fp\%}))$,
- odchylenie standardowe błędów funkcji kosztu: $\widehat{\sigma}_{\delta Fp}$ i jego przedział ufności przy poziomie ufności 0,95, wyznaczony ze wzoru (4.164): $(g_d(\widehat{\sigma}_{\delta Fp}), g_g(\widehat{\sigma}_{\delta Fp}))$,
- błąd graniczny funkcji kosztu, wyznaczony dla poziomu ufności 0,95: $\widehat{\delta}_{grFp\%}$ i jego przedział ufności: $(g_d(\widehat{\delta}_{grFp\%}), g_g(\widehat{\delta}_{grFp\%}))$,
- średni błąd absolutny: $\widehat{\delta}_{absFp\%}$ i jego przedział ufności przy poziomie ufności 0,95: $(g_d(\widehat{\delta}_{absFp\%}), g_g(\widehat{\delta}_{absFp\%}))$.

Tablica 4.19. Zestawienie estymatorów parametrów rozkładu błędów funkcji kosztu. Źródło: opracowanie własne.

Wariant algorytmu	$\widehat{\delta}_{Fp\%}$ $(g_d(\widehat{\delta}_{Fp\%}), g_g(\widehat{\delta}_{Fp\%}))$ %	$\widehat{\sigma}_{\delta Fp}$ $(g_d(\widehat{\sigma}_{\delta Fp}), g_g(\widehat{\sigma}_{\delta Fp}))$ %	$\widehat{\delta}_{grFp\%}$ $(g_d(\widehat{\delta}_{grFp\%}), g_g(\widehat{\delta}_{grFp\%}))$ %	$\widehat{\delta}_{absFp\%}$ $(g_d(\widehat{\delta}_{absFp\%}), g_g(\widehat{\delta}_{absFp\%}))$ %
AE3	-0,0073 (-0,0238, 0,0091)	0,8403 (0,8288, 0,8521)	$\pm 1,6806$ $\pm (1,6576, 1,7042)$	0,6699 (0,6630, 0,6817)
KAE	0,0234 (-0,0062, 0,0531)	0,8302 (0,8097, 0,8517)	$\pm 1,6604$ $\pm (1,6195, 1,7036)$	0,6632 (0,6477, 0,6814)
SAE	0,0165 (-0,0383, 0,0714)	2,7992 (2,7610, 2,8386)	$\pm 5,5985$ $\pm (5,5220, 5,6772)$	2,2365 (2,2088, 2,2708)

Rozkłady błędów funkcji kosztu zobrazowano histogramami na rys. 4.38. Wariancja błędów funkcji kosztu w SAE jest o wiele większa od wariancji w algorytmach AE3 i KAE. Spowodowane jest to znacznie mniejszą liczbą zmiennych losowych w funkcji kosztu (4.150) niż w funkcji (4.2).




Rys. 4.38. Histogramy błędów funkcji kosztu: a) dla AE3, b) dla KAE, c) dla SAE. Źródło: opracowanie własne.

Tablica 4.20. Zestawienie wyników testów statystycznych hipotez o zgodności rozkładu błędów funkcji kosztu z rozkładem normalnym. Źródło: opracowanie własne.

Wariant algorytmu	Test	Poziom istotności	Wartość krytyczna	Statystyka testowa uzyskana z
		testu α	rozkładu statystyki testowej $T(\alpha)$	próby T_{emp}
AE3	K-S	0,05	0,0135	0,0049
	Lill	0,05	0,0088	0,0049
	J-B	0,05	5,9914	5,2433
KAE	K-S	0,05	0,0135	0,0062
	Lill	0,05	0,0088	0,0062
	J-B	0,05	5,9914	2,8579
SAE	K-S	0,05	0,0135	0,0060
	Lill	0,05	0,0088	0,0060
	J-B	0,05	5,9914	4,2114


Wobec założeń 2 i 4 oraz centralnego twierdzenia granicznego [Bra98] przypuszcza się, że błędy $\delta_{Fp\%}$ nakładające się na wartość funkcji kosztu mają rozkłady normalne lub zbliżone do normalnych. Hipotezy zerowe o normalności rozkładów zweryfikowano testem Kołmogorowa – Smirnowa (K-S) [Bob88], [Dom79], [Mat01], Lillieforsa (Lill) [Kob98], [Mat01] oraz Jarque – Bera (J-B) [Koś99], [Mat01]. Wyniki testów, przedstawione w tabelicy 4.20, nie dają podstaw do odrzucenia hipotez o normalności rozkładów błędów funkcji kosztu.

Na błędy określania obciążeń poszczególnych jednostek wytwórczych mają wpływ jedynie błędy $\delta_{gr\epsilon i\%}$, $\bar{\delta}_{absPz\%}$ oraz δ_p . Dla przykładu rozpatrywanego powyżej otrzymano rozkłady w/w błędów o dystrybuantach $F(\delta_{Pi\%})$ przedstawionych na rys. 4.39. W wariacie algorytmów AE3 oraz KAE błędy liczone dla każdej godziny t .




Rys. 4.39. Rodzina empirycznych dystrybuant błędów określania obciążeń poszczególnych jednostek: a) dla AE3, b) dla KAE, c) dla SAE. Źródło: opracowanie własne.


Na rys. 4.39 można wyróżnić kilka charakterystycznych kształtów dystrybuant błędów $\delta_{p_i\%}$:




1. Błędy są zerowe. Kształt charakterystyczny dla jednostek, które:
 - są odstawione,
 - pracują przy minimum technicznym, z przyrostem ε_k znacznie poniżej swojego przyrostu minimalnego $\varepsilon_k(P_{nmin})$,
 - pracują z mocą osiągalną, z przyrostem ε_k znacznie powyżej swojego przyrostu maksymalnego $\varepsilon_k(P_{nmax})$.




2. Błędy ujemne nie zachodzą. Kształt charakterystyczny dla jednostek pracujących z mocą minimum technicznego, z przyrostem ε_k nieznacznie poniżej swojego przyrostu minimalnego $\varepsilon_k(P_{nmin})$.




3. Błędy ujemne są ograniczone. Kształt charakterystyczny dla jednostek pracujących w pobliżu minimum technicznego, z przyrostem ε_k nieznacznie powyżej swojego przyrostu minimalnego $\varepsilon_k(P_{nmin})$.



4. Błędy dodatnie nie zachodzą. Kształt charakterystyczny dla jednostek pracujących z mocą osiągalną, z przyrostem ε_k nieznacznie powyżej swojego przyrostu maksymalnego $\varepsilon_k(P_{nmax})$.



5. Błędy dodatnie są ograniczone. Kształt charakterystyczny dla jednostek pracujących w pobliżu mocy osiągalnej, z przyrostem ε_k nieznacznie poniżej swojego przyrostu maksymalnego $\varepsilon_k(P_{nmax})$.



6. Błędy ujemne i dodatnie zachodzą z tą samą częstością. Kształt charakterystyczny dla jednostek średnio obciążonych; wahania przyrostu względnego ε_k nie powodują dojścia obciążenia do wartości granicznych.

Przy pominięciu ograniczeń technicznych narzuconych na JW (nieograniczony zakres generacji), rozkłady błędów wykazują podobieństwo do rozkładu normalnego. Potwierdzają to testy statystyczne przeprowadzone dla przypadków, w których obciążenia jednostek nie osiągają wartości granicznych lub osiągają je w nielicznych przypadkach (kształt dystrybuanty zbliżony do kształtu nr 6). Zakresy estymatorów parametrów rozkładów błędów dla tych przypadków zestawiono w tabelicy 4.21.



Tablica 4.21. Zestawienie estymatorów parametrów rozkładu błędów określania obciążeń jednostek wytwórczych. Źródło: opracowanie własne.

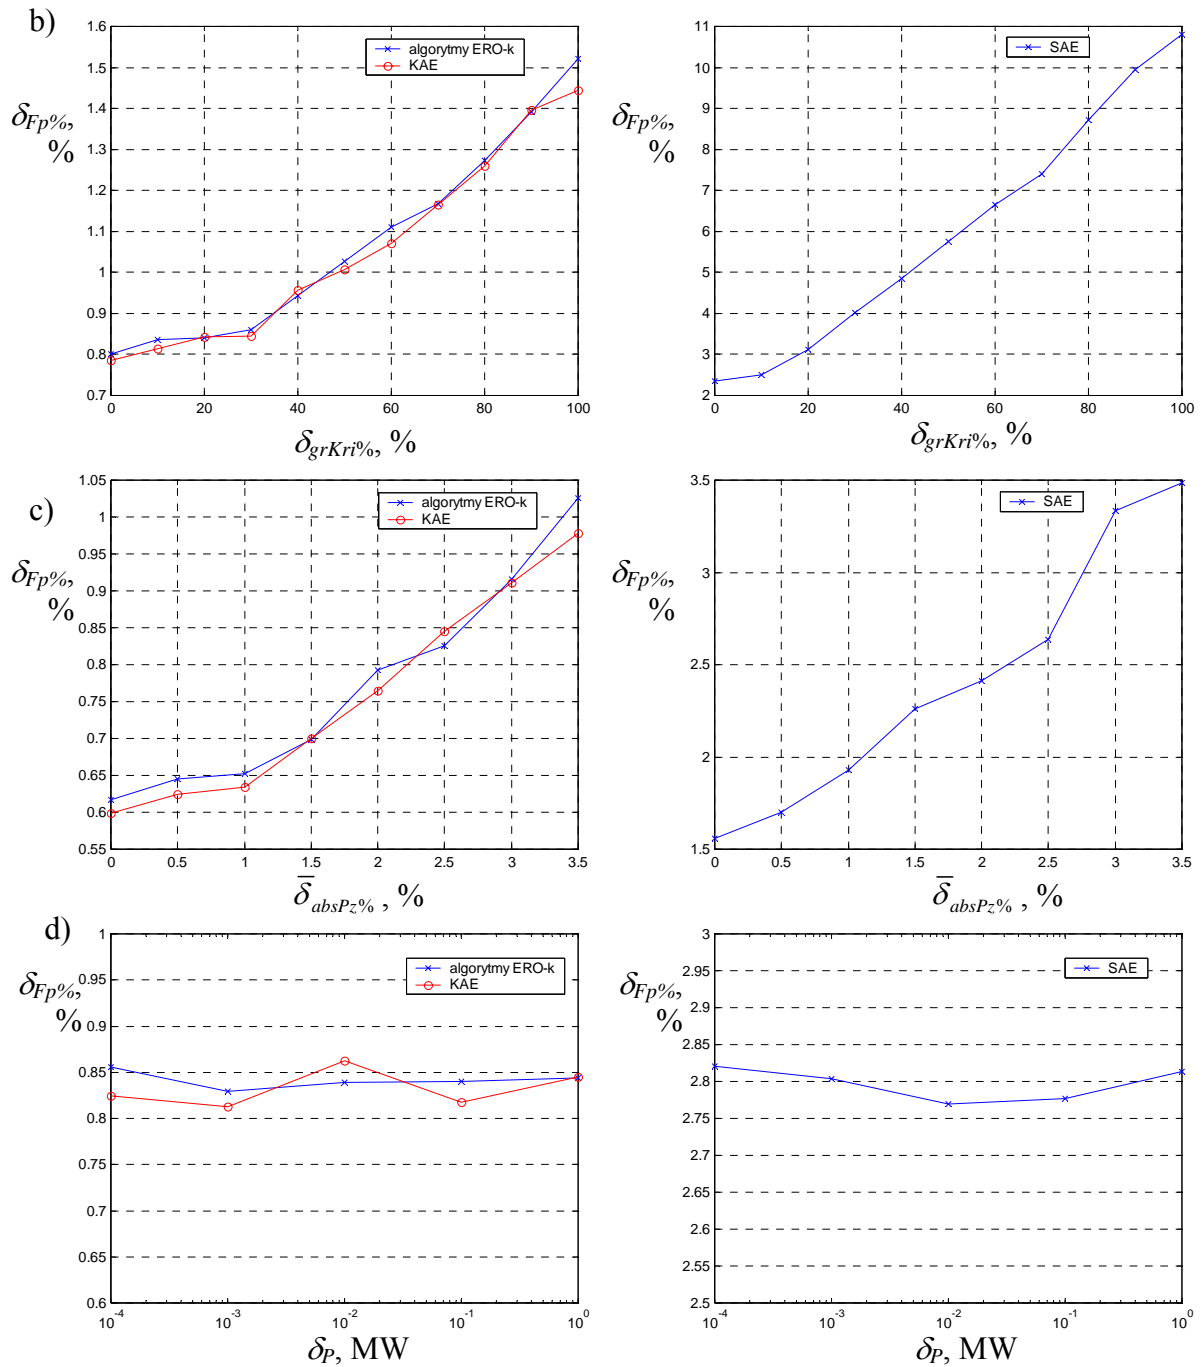
Wariant algorytmu	$\widehat{\delta}_{Pi\%}$ %	$\widehat{\sigma}_{\delta Pi}$ %	$\widehat{\delta}_{grPi\%}$ %	$\widehat{\delta}_{absPi\%}$ %
AE3	-0,56 ÷ 0,82	8,75 ÷ 10,81	±(17,51 ÷ 21,64)	6,99 ÷ 8,90
KAE	-0,58 ÷ 0,83	8,76 ÷ 10,81	±(17,52 ÷ 21,64)	6,70 ÷ 8,70
SAE	0,57	9,14	±18,28	7,40

gdzie: $\widehat{\delta}_{Pi\%}$ – estymowany błąd średni określania obciążeń JW; $\widehat{\sigma}_{\delta Pi}$ – estymowane odchylenie standardowe błędów określania obciążeń JW; $\widehat{\delta}_{grPi\%}$ – estymowany błąd graniczny określania obciążeń JW; $\widehat{\delta}_{absPi\%}$ – estymowany błąd średni absolutny określania obciążeń JW.

Tablica 4.22. Wpływ błędów poszczególnych parametrów modeli optymalizacyjnych na błędy funkcji kosztu. Źródło: opracowanie własne.

Wariant algorytmu	$\delta_{grKzi\%}$, $\delta_{gr\epsilon i\%}$ %	$\delta_{grKri\%}$ %	$\widehat{\delta}_{absPz\%}$ %	δ_P MW	$\widehat{\sigma}_{\delta Fp}$ %	$\widehat{\delta}_{grFp\%}$ %	$\widehat{\delta}_{absFp\%}$ %
AE3	0 ÷ 10	15	2,5	0,0001	0,58 ÷ 1,59	1,16 ÷ 3,19	0,46 ÷ 1,29
	4	0 ÷ 100	2,5	0,0001	0,80 ÷ 1,52	1,60 ÷ 3,04	0,63 ÷ 1,22
	4	15	0 ÷ 3,5	0,0001	0,61 ÷ 1,02	1,23 ÷ 2,05	0,49 ÷ 0,80
	4	15	2,5	0,0001 ÷ 1	0,82 ÷ 0,85	1,65 ÷ 1,71	0,66 ÷ 0,68
KAE	0 ÷ 10	15	2,5	0,0001	0,60 ÷ 1,61	1,20 ÷ 3,23	0,47 ÷ 1,27
	4	0 ÷ 100	2,5	0,0001	0,78 ÷ 1,44	1,57 ÷ 2,89	0,63 ÷ 1,14
	4	15	0 ÷ 3,5	0,0001	0,60 ÷ 0,98	1,19 ÷ 1,95	0,48 ÷ 0,77
	4	15	2,5	0,0001 ÷ 1	0,81 ÷ 0,86	1,62 ÷ 1,72	0,65 ÷ 0,68
SAE	0 ÷ 10	15	2,5	0,0001	2,84 ÷ 3,14	5,69 ÷ 6,27	2,27 ÷ 2,52
	4	0 ÷ 100	2,5	0,0001	2,34 ÷ 10,80	4,69 ÷ 21,61	1,89 ÷ 8,60
	4	15	0 ÷ 3,5	0,0001	1,56 ÷ 3,48	3,11 ÷ 6,96	1,24 ÷ 2,78
	4	15	2,5	0,0001 ÷ 1	2,76 ÷ 2,82	5,53 ÷ 5,64	2,19 ÷ 2,25





Rys. 4.40. Zależności błędów funkcji kosztu od błędów poszczególnych parametrów modeli optymalizacyjnych: a) $\delta_{grKzi}\%$, $\delta_{grzi}\%$, b) $\delta_{grKri}\%$, c) $\bar{\delta}_{absPz}\%$, d) δ_P . Źródło: opracowanie własne.

Analizując wrażliwość proponowanych modeli optymalizacyjnych badano wpływ błędów granicznych lub średnich poszczególnych parametrów (charakterystyk i prognozy) na błędy funkcji kosztu, przy założeniu, że pozostałe parametry obciążone są stałymi błędami granicznymi lub średnimi. Symulacje przeprowadzono wg algorytmu Monte Carlo przedstawionego powyżej, przy $n = 1000$. W tabelicy 4.22 zestawiono rezultaty eksperymentów, a na rys. 4.40 zależności błędów funkcji kosztu od błędów poszczególnych parametrów modeli optymalizacyjnych.

Wrażliwość błędu określania obciążeń JW na błędy $\delta_{gr\bar{a}i\%}$, $\bar{\delta}_{absPz\%}$ oraz δ_P zobrazowano w tablicy 4.23.

Tablica 4.23. Wpływ błędów poszczególnych parametrów modeli optymalizacyjnych na błędy określania obciążeń JW. Źródło: opracowanie własne.

Wariant algorytmu	$\delta_{grKzi\%}$ $\delta_{gr\bar{a}i\%}$ %	$\delta_{grKri\%}$ %	$\bar{\delta}_{absPz\%}$ %	δ_P MW	$\hat{\sigma}_{\delta P}$ %	$\hat{\delta}_{grFP\%}$ %	$\hat{\bar{\delta}}_{absFP\%}$ %
ERO-k	0 ÷ 10	15	2,5	0,0001	6,04 ÷ 18,12	12,09 ÷ 36,24	4,83 ÷ 15,02
	4	15	0 ÷ 3,5	0,0001	8,02 ÷ 11,11	16,04 ÷ 22,22	6,37 ÷ 8,87
	4	15	2,5	0,0001 ÷ 1	9,64 ÷ 9,73	19,28 ÷ 19,47	7,72 ÷ 7,78
KAE	0 ÷ 10	15	2,5	0,0001	6,28 ÷ 18,19	12,56 ÷ 36,39	5,00 ÷ 15,11
	4	15	0 ÷ 3,5	0,0001	8,14 ÷ 11,03	16,28 ÷ 22,06	6,42 ÷ 8,79
	4	15	2,5	0,0001 ÷ 1	9,74 ÷ 9,99	19,48 ÷ 19,99	7,79 ÷ 7,98
SAE	0 ÷ 10	15	2,5	0,0001	5,82 ÷ 16,09	11,65 ÷ 32,51	4,67 ÷ 13,50
	4	15	0 ÷ 3,5	0,0001	7,33 ÷ 10,13	14,66 ÷ 20,25	5,83 ÷ 8,18
	4	15	2,5	0,0001 ÷ 1	9,14 ÷ 9,65	18,28 ÷ 19,30	7,30 ÷ 7,72

Dobór dopuszczalnego błędu niezbilansowania δ_P

Aby uniknąć niejednoznaczności przy ocenie rozwiązań i zapewnić poprawne działanie mechanizmów selekcji, dopuszczalny błąd δ_P powinien być dostatecznie mały. Minimalny koszt rozwiązania $a - K_{z\min a}$ wynika z rozdziału mocy ($P_z - \delta_P$) na współpracujące jednostki, koszt maksymalny $K_{z\max a}$ otrzymuje się dla rozdziału mocy ($P_z + \delta_P$). Stąd tolerancja z jaką może być ocenione rozwiązanie a : $\Delta K_{za} = K_{z\max a} - K_{z\min a}$, zależy od δ_P . Niejednoznaczność oceny rozwiązań pojawia się, gdy zakresy kosztów ($K_{z\min}$, $K_{z\max}$) dwóch rozwiązań zachodzą na siebie. Przyjmując $\delta_P = 1$ MW, tolerancja ΔK_z dla najlepszych rozwiązań zadania określonego w podrozdziale 4.1, znalezionych przez proponowane algorytmy optymalizacyjne, wynosi ponad 1600 zł, co prowadzi do wyżej wspomnianych niejednoznaczności oceny, gdyż różnice pomiędzy najlepszymi rozwiązaniami są znacznie mniejsze od tej tolerancji. Zakłada się, że dostateczną tolerancją z jaką wyznacza się koszty rozwiązań jest $\Delta K_z = 1$ zł. W celu określenia błędu δ_P zapewniającego tolerancję na takim poziomie przeprowadzono następujące rozumowanie. Niech najmniej ekonomiczna jednostka pracuje przy swoim obciążeniu osiągalnym $P_{n\max i}$ (wtedy występuje największy przyrost względny kosztów zmiennych). Niech wtedy niezbilansowanie dla jednej godziny okresu optymalizacji T wynosi $+\delta_P$ MW. Zmniejszenie obciążenia tego bloku o $2\delta_P$ MW spowoduje maksymalną zmianę kosztów zmiennych rozwiązania, przy dotrzymaniu warunku bilansu:

$$\Delta K_z = T [K_{zi}(P_{nmaxi}) - K_{zi}(P_{nmaxi} - 2\delta_p)] \quad (4.167)$$

Przyjmując, że najmniej ekonomiczną jednostką jest jednostka nr 9 i podstawiając do powyższego wzoru $T = 24$, $P_{nmax9} = 350$ MW oraz $+\delta_p = 1$ MW otrzymano $\Delta K_z = 2124$ zł. Dla zapewnienia tolerancji $\Delta K_z \leq 1$ zł przyjęto $\delta_p = 0,0001$ MW, co dało $\Delta K_z = 0,21$ zł. W rzeczywistości dla $\delta_p = 0,0001$ MW tolerancja ΔK_z będzie mniejsza, gdyż moc $2\delta_p$ MW będzie przejęta nie przez jednostkę najmniej ekonomiczną, lecz rozłoży się na wszystkie załączone do ruchu jednostki wg kryterium ERO.

Wnioski

1. Przy typowych błędach granicznych charakterystyk kosztowych oraz średnich prognozy zapotrzebowania, algorytm AE3 reprezentujący modele ERO-k, generował rozwiązania quasi-optymalne, które tylko w 3 przypadkach na 100 można sprowadzić do rozwiązania optymalnego, poprzez korektę obciążeń jednostek. W pozostałych przypadkach harmonogramy wynikające z rozwiązania quasi-optimalnego były nieoptymalne (lecz dopuszczalne), co skutkowało wzrostem kosztów wytwarzania średnio o 0,1173% (3026 zł). Model SAE jest znacznie mniej wrażliwy na błędy charakterystyk i prognozy zapotrzebowania od modelu AE3, co wynika zapewne z mniejszej elastyczności tego modelu (rozwiązania dla kolejnych chwil t zdeterminowane są rozwiązaniami dla chwil poprzedzających). Harmonogramy pracy JW wynikające z rozwiązań quasi-optimalnych znalezionych przez algorytm SAE w żadnym przypadku nie były optymalne, lecz dodatkowe koszty względne były średnio o ponad połowę mniejsze niż w algorytmie AE3 ($\widehat{\delta}_{F_{opt}\%} = 0,0505\%$, tj. 1303 zł). Harmonogramy te w 96 przypadkach na 100 pokrywały się z harmonogramami otrzymanymi w warunkach bez błędów parametrów lub różniły się od nich nieznacznie.
2. Typowe błędy charakterystyk kosztowych oraz prognozy zapotrzebowania, dla których przeprowadzono symulacje komputerowe, wpływają w istotny sposób na wartość funkcji kosztu oraz obciążeń JW. Średni błąd funkcji kosztu dla modeli optymalizacyjnych AE3 oraz KAE jest zbliżony i wynosi ok. 0,66%, co daje błąd względny (liczony dla rozwiązania P_{nopt}) – 17 027 zł. Wpływ ten jest znacznie większy ($\widehat{\delta}_{absFp\%} = 2,23\%$) w SAE, gdzie funkcja kosztu zależna jest od mniejszej liczby zmiennych losowych. Obciążenia JW w badanych modelach określone są ze średnią dokładnością ok. $6,99 \div 8,90\%$. Wpływ analizowanych błędów parametrów wejściowych jest nieunikniony we wszystkich modelach optymalizacyjnych stosowanych do ERO.
3. Należy podkreślić, że wszystkie obliczenia optymalizacyjne wykonano na charakterystykach i prognozie obciążonych takimi samymi błędami (granicznymi lub średnimi), więc ich wpływ na rezultaty optymalizacji daje podstawy do analizy porównawczej badanych modeli optymalizacyjnych. Koszty rozwiązań ch generowanych

w procesach ewolucyjnych i w procesach wyżarzania również określane są z jednakowymi błędami, co zapewnia właściwe działanie mechanizmów selekcji.

4. Wrażliwość modeli optymalizacyjnych AE3 oraz KAE na błędy $\delta_{grKzi\%}$, $\delta_{gr\bar{a}\%}$, $\delta_{grKri\%}$ oraz $\bar{\delta}_{absPz\%}$ w zakresie ich typowych zmienności jest podobna. Model SAE cechuje kilkakrotnie większa wrażliwość, szczególnie na błąd charakterystyk kosztów rozruchów, gdyż w funkcji kosztu (4.150) koszty rozruchu uwzględnia się zarówno dla jednostek uruchamianych jak i odstawianych w chwili t , stąd stosunek składnika kosztów rozruchów do składnika kosztów zmiennych jest większy, niż w modelach AE3 oraz KAE, wykorzystujących funkcję kosztu postaci (4.2).
5. Zadaniem modeli optymalizacyjnych jest zaplanowanie harmonogramów pracy JW oraz ich obciążeń. W warunkach realizacji planu zarówno charakterystyki kosztowe, jak i przebieg zapotrzebowania odbiegają od tych, które przyjęto w modelach optymalizacyjnych. W związku z tym obciążenia jednostek, korygowane na bieżąco regulatorem centralnym ARCM, odbiegają od zaplanowanych. Przy dużym błędzie prognozy może dojść do sytuacji, że załączone do ruchu jednostki nie są w stanie pokryć zapotrzebowania i wymagane jest wcześniejsze uruchomienie (lub odstawienie) dodatkowych JW. Aby tego uniknąć istotne jest utrzymanie dużej dokładności prognozy oraz odpowiedniej rezerwy wirującej. W przeprowadzonych badaniach symulacyjnych nie wystąpił taki przypadek, co świadczy o właściwym doborze poziomu rezerwy.

5. EKONOMICZNY ROZDZIAŁ OBCIĄŻEŃ NA POZIOMIE SYSTEMU ELEKTROENERGETYCZNEGO

5.1. SFORMUŁOWANIE ZADANIA. FUNKCJA KOSZTU. OGRANICZENIA

ERO na poziomie systemu elektroenergetycznego ma na celu określenie obciążeń czynnych netto $P_{ni}(t)$ współpracujących w systemie JW, w taki sposób, aby koszty produkcji i przesyłu energii elektrycznej były najmniejsze. Przyjmuje się horyzont optymalizacji T (najczęściej 24 h) oraz krok dyskretyzacji Δt . Jednostki wytwórcze opisane są charakterystykami kosztów zmiennych $K_{zi}(P_{ni})$, charakterystykami przyrostów względnych $\varepsilon_{ki}(P_{ni})$ oraz kosztów rozruchów $K_{ri}(t_{pi})$. Funkcja kosztu zdefiniowana jest wzorem (4.2), takim samym jak w zadaniu ERO na poziomie elektrowni, przy czym N oznacza tu liczbę wszystkich dyspozycyjnych w SEE bloków energetycznych. Poziom rezerwy wirującej określa się ze wzoru (4.1). Koszty rozruchów JW pozostających w postoju do końca okresu optymalizacji T oblicza się ze wzoru (4.4). Na rozwiązania narzuca się następujące ograniczenia:

- zakresów generacji poszczególnych jednostek (4.6),
- zakresu generacji grupy jednostek (4.7) i (4.8),
- minimalnych czasów postojów jednostek w rezerwie (4.9),
- minimalnych czasów pracy jednostek po rozruchu (4.10),
- bilansu mocy:

$$\forall t: \sum_{i=1}^N [\alpha_i(t) P_{ni}(t)] = P_z(t) + \Delta P_s(t) \quad (5.1)$$

gdzie: $P_z(t)$ – przebieg zapotrzebowania (suma mocy obciążeń węzłowych) pokrywany przez elektrownie ciepłe, MW; $\Delta P_s(t)$ – starty mocy czynnej w systemie w godzinie t , MW.

Przebieg zapotrzebowania $P_z(t)$ jest sumą mocy obciążeń węzłowych pomniejszoną o moc elektrowni wodnych przepływowych oraz moc elektrowni wodnych zbiornikowych i pompowych, których praca optymalizowana jest zwykle odrębnymi algorytmami.

Stan początkowy i -tej JW reprezentuje zmienna t_{psi} określana tak samo jak w zadaniu ERO dla elektrowni.

Straty mocy czynnej w SEE ΔP_s wynikają z rozptyłu mocy. Zadanie rozptyłu mocy polega na wyznaczeniu wektora zespolonych napięć węzłowych, dla zadanej konfiguracji sieci i zadanych wymuszeń: wektorów mocy zapotrzebowanych i generowanych w węzłach SEE. Z napięć węzłowych można analitycznie obliczyć przepływy w gałęziach i straty mocy w sieci. Zagadnienie rozptyłu mocy opisano bardziej szczegółowo w dodatku 7.

Straty mocy czynnej w sieci przesyłowej można określić ze wzoru:

$$\Delta P_s = \sum_{i=1}^{l_g} P_{gi} - \sum_{i=1}^{l_o} P_{zi} = \sum_{i=1}^w P_i \quad (5.2)$$

gdzie: P_{gi} – moc czynna wytwarzana w i -tym węźle generatorowym, MW; P_{zi} – moc czynna zapotrzebowana w i -tym węźle odbiorczym, MW; P_i – moc czynna w i -tym węźle SEE, MW; l_g – liczba węzłów generatorowych; l_o – liczba węzłów odbiorczych; w – ogólna liczba węzłów w SEE.

5.2. MODELE OPTIMALIZACYJNE DO EKONOMICZNEGO ROZDZIAŁU OBCIĄŻEŃ NA POZIOMIE SYSTEMU ELEKTROENERGETYCZNEGO

Do zadania ERO na poziomie systemu elektroenergetycznego można stosować wszystkie proponowane dla ERO na poziomie elektrowni modele optymalizacyjne, przy czym algorytmy obliczeniowe należy zmodyfikować. Modyfikacje polegają na tym, że po określeniu rozwiązania spełniającego bilans mocy bez strat sieciowych (4.5), dla każdej godziny t dokonuje się obliczeń rozptyłów mocy i określa się straty sieciowe $\Delta P_s(t)$. Straty te rozdziela się na jednostki w ten sam sposób, w jaki rozdziela się moc zapotrzebowaną $P_z(t)$. W efekcie otrzymuje się nowe rozwiązanie spełniające bilans mocy ze stratami przesyłowymi (5.1). Wobec powyższego, w algorytmach obliczeniowych należy zmienić wyszczególnione poniżej punkty:

- w algorytmach ewolucyjnych do zadania ERO-k, których schemat zamieszczono w podrozdziale 4.4.1.4, punkty 3.2.2.a i 3.2.2.b przyjmują postać:
 - 3.2.2.a. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla naprawionych wersji osobników spełniających ograniczenia (4.9) i (4.10). Obliczenie rozptyłów mocy i strat sieciowych. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązań spełniających bilans mocy (5.1). Wyznaczenie kosztów zmiennych tych rozwiązań.
 - 3.2.2.b. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla osobników dopuszczalnych ze względu na ograniczenia (4.7) ÷ (4.10). Obliczenie rozptyłów mocy i strat sieciowych dla tych osobników. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązań spełniających bilans mocy (5.1). Wyznaczenie kosztów zmiennych tych rozwiązań.
- w algorytmach symulowanego wyżarzania do zadania ERO-k, których schemat zamieszczono w podrozdziale 4.4.2.2, punkty 4.2.a i 4.2.b przyjmują postać:
 - 4.2.a. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla naprawionej wersji punktu spełniającego ograniczenia (4.9) i (4.10). Obliczenie rozptyłów mocy i strat sieciowych. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązania spełniającego bilans mocy (5.1). Wyznaczenie kosztów zmiennych tego rozwiązania.

- 4.2.b. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla punktu dopuszczalnego ze względu na ograniczenia (4.7) ÷ (4.10). Obliczenie rozptyłów mocy i strat sieciowych. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązania spełniającego bilans mocy (5.1). Wyznaczenie kosztów zmiennych tego rozwiązania.
- w algorytmie hybrydowym SW+AE do zadania ERO-k, którego schemat zamieszczono w podrozdziale 4.4.3, punkty 4.2.a i 4.2.b przyjmują postać:
 - 4.2.a. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla naprawionych wersji punktów spełniających ograniczenia (4.9) i (4.10). Obliczenie rozptyłów mocy i strat sieciowych. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązań spełniających bilans mocy (5.1). Wyznaczenie kosztów zmiennych tych rozwiązań.
 - 4.2.b. Ekonomiczny rozdział obciążeń bez uwzględnienia strat sieciowych, dla punktów dopuszczalnych ze względu na ograniczenia (4.7) ÷ (4.10). Obliczenie rozptyłów mocy i strat sieciowych. Ponowne obliczenia ERO z uwzględnieniem strat sieciowych i określenie w ten sposób rozwiązań spełniających bilans mocy (5.1). Wyznaczenie kosztów zmiennych tych rozwiązań.
 - w kompleksowym algorytmie ewolucyjnym KAE do zadania ERO-z, którego schemat zamieszczono w podrozdziale 4.5.1.4, punkt 3.2.3 przyjmuje postać:
 - 3.2.3. Naprawa osobników dopuszczalnych ze względu na warunki (4.7) ÷ (4.10), a nie spełniających warunku bilansu mocy (4.5). Obliczenie rozptyłów mocy i strat sieciowych. Drugi etap naprawy osobników naruszających warunek bilansu z uwzględnieniem strat sieciowych (5.1) (patrz niżej). Wyznaczenie kosztów zmiennych, kosztów rozruchów i wartości funkcji kosztu (4.2) dla osobników naprawionych.
 - w sekwencyjnym algorytmie ewolucyjnym SAE do zadania ERO-z, którego schemat zamieszczono w podrozdziale 4.5.2.3, punkt 3.1.2.2 przyjmuje postać:
 - 3.1.2.2. Naprawa osobników dopuszczalnych ze względu na warunki (4.7) ÷ (4.10), a nie spełniających warunku bilansu mocy (4.5) w chwili t . Obliczenie rozptyłów mocy i strat sieciowych w chwili t . Drugi etap naprawy osobników naruszających warunek bilansu z uwzględnieniem strat sieciowych (5.1) (patrz niżej). Wyznaczenie kosztów zmiennych, kosztów rozruchów i wartości funkcji kosztu (4.150) dla osobników naprawionych

W modelach optymalizacyjnych do ERO-k straty sieciowe rozdziela się wg różnych przyrostów względnych kosztów zmiennych. Algorytm rozdziału obciążeń w tym przypadku jest taki sam jak przedstawiony w podrozdziale 4.2, przy czym należy w nim zmienić warunek (4.13) na warunek:

$$\left| \sum_{i=1}^N \alpha_i P_{ni}(\varepsilon') - P_z - \Delta P_s \right| \leq \delta_p \quad (5.3)$$

oraz warunek (4.14) na warunek:

$$\sum_{i=1}^N \alpha_i P_{ni}(\varepsilon') > P_z + \Delta P_s \quad (5.4)$$

Drugi etap naprawy w algorytmach KAE ze strategią z kryterium jednostkowych kosztów zmiennych SN1 przebiega wg algorytmu naprawy zaprezentowanego w podrozdziale 4.5.1.3, przy czym w algorytmie tym kontroluje się warunki bilansu mocy ze stratami sieciowymi. Wymaga to korekty tego algorytmu w punktach 1, 2, 1.4 i 2.4:

1. Jeśli $P_z(t) + \Delta P_s(t) - \sum_{i=1}^N [\alpha_i(t) P_{ni}(t)] > \delta_p$, wykonaj.;

2. Jeśli $\sum_{i=1}^N [\alpha_i(t) P_{ni}(t)] - P_z(t) - \Delta P_s(t) > \delta_p$, wykonaj.;

1.4. i 2.4. Powtarzaj do momentu spełnienia warunki bilansu (5.1) z błędem δ_p .

W przypadku strategii naprawy z kryterium przyrostów względnych kosztów zmiennych (opisanej w podrozdz. 4.5.1.3), drugi etap naprawy przebiega tak samo jak pierwszy, przy czym warunkiem zakończenia procedury dociażania lub odciążania jest spełnienie warunku bilansu ze stratami (5.1).

Przyjęte do obliczeń rozplwyowych moce bierne w węzłach sieci należy określić odrębną metodą optymalizacyjną lub zastosować metodę „P- δ ” rozplwyów mocy [Kre96]. Metoda ta polega na przyjęciu założenia, że w całej sieci występują napięcia znamionowe, a więc przepływy mocy biernej są równe zero. Uwzględniając znacznie słabszą zależność mocy czynnych od modułów napięć węzłowych niż od kątów fazowych tych napięć, z macierzy Jakobiego (D7.10) (dodatek 7) można wyeliminować podmacierz J_4 . Pozwala to szacować straty jedynie na podstawie kątów fazowych napięć w węzłach sieci.

6. WNIOSKI KOŃCOWE

W rozprawie przedstawiono modele optymalizacyjne do ekonomicznego rozdziału obciążeń i doboru składu jednostek wytwórczych, wykorzystujące algorytmy ewolucyjne i symulowane wyżarzanie. Opracowano modele do ERO na poziomie elektrowni z wykorzystaniem algorytmów ewolucyjnych (w wariancie kombinowanym i zintegrowanym), algorytmów symulowanego wyżarzania i algorytmów hybrydowych, łączących proces wyżarzania z procesem ewolucyjnym. Wszystkie modele oprogramowano i wykonano przy ich użyciu przykładowe obliczenia optymalizacyjne. Dokonano analizy dokładności proponowanych modeli optymalizacyjnych. Opracowano metodyki ekonomicznego rozdziału obciążeń na poziomie systemu elektroenergetycznego z wykorzystaniem AE, SW i modelu hybrydowego.

Nawiązując do tej rozprawy, przeprowadzone analizy i obliczenia optymalizacyjne można podsumować następująco:

- Modele optymalizacyjne wykorzystujące algorytmy ewolucyjne, a także symulowane wyżarzanie, mogą być z powodzeniem stosowane do problemu ekonomicznego rozdziału obciążeń oraz doboru składu jednostek wytwórczych. Algorytmy te wykazują elastyczność w sensie dowolnego kształtowania funkcji kryterialnej oraz uwzględniania jej ograniczeń. Ciągłe nieliniowe zadanie ERO i kombinatoryczne zadanie DSJW mogą być rozwiązywane łącznie, za pomocą jednego algorytmu.
- Klasyczne metody ERO: metoda równych przyrostów względnych kosztów zmiennych oraz metoda programowania dynamicznego, jak pokazano w rozdz. 2, dokonują chwilowych optymalizacji rozdziału obciążeń (tzw. ERO „w punkcie”). Rozdział ten jednak nie jest optymalny z punktu widzenia całego okresu optymalizacji. Dobór składu jednostek wytwórczych metodą charakterystyk czasów granicznych jest metodą przybliżoną i uproszczoną. Jak wykazały badania opisane w podrozdz. 4.4.4.1, w zadaniu DSJW na poziomie elektrowni, algorytm ten dał rozwiązania dalekie od optymalnych. Zaprojektowane algorytmy ewolucyjne, algorytmy symulowanego wyżarzania oraz algorytmy hybrydowe SW+AE pozwalały uzyskać dla tego zadania rozwiązanie optymalne lub bliskie optymalnego.

Efektywność działania AE osiągnięto poprzez wprowadzenie oryginalnych, specjalizowanych operatorów genetycznych, reprezentacji zmiennych i metod eliminacji ograniczeń funkcji kosztu. W wersji kombinowanej algorytmu, spośród operatorów najlepsze działanie w przeszukiwaniu przestrzeni rozwiązań wykazały: operator mutacji zależnej od liczby jednostek potrzebnych do pokrycia zapotrzebowania i kosztów wytwarzania jednostek MB3 oraz operator transpozycji. Zaproponowana reprezentacja binarna i całkowitoliczbowa momentów załączeń i odstawień JW pozwoliła uzyskać najlepsze rezultaty bez stosowania specjalizowanych metod mutacji.

Algorytm symulowanego wyżarzania działał najlepiej z adaptacyjnym zmodyfikowanym schematem Aartsa, dopasowującym proces wyżarzania do aktualnego

etapu przeszukiwań oraz z operatorami mutacji MB3 i transpozycji w roli operatorów przesunięcia. Wobec swojej sekwencyjnej struktury, algorytm SW działał jednak znacznie dłużej od AE. Pozytywne cechy AE i SW próbowano połączyć w algorytmie hybrydowym.

Zaletą podejścia zintegrowanego do zadania ERO i DSJW jest dowolne kształtowanie funkcji kosztu; nie musi ona być ciągła i wypukła, co umożliwia uwzględnienie w obliczeniach dokładniejszych, bliższych rzeczywistym charakterystyk kosztowych JW. AE w wersji kompleksowej, wobec dużej liczby zmiennych binarnych i ciągłych, przeszukuje znacznie większą przestrzeń rozwiązań, niż w wersji kombinowanej. W związku z tym wydłuża się czas do momentu znalezienia dobrego rozwiązania. Czas ten można znacznie ograniczyć stosując podejście sekwencyjne, chociaż jest ono bardziej zdeterminowane i nie gwarantuje optymalizacji globalnej w okresie T .

Z uwagi na równoległą strukturę AE, dającą możliwość implementacji na maszynach równoległych, czas działania algorytmu można znacznie zredukować.

Opracowane modele mogą być wykorzystane do optymalizacji rozdziału obciążeń w pojedynczej elektrowni jak i w całym systemie elektroenergetycznym. Mogą znaleźć też zastosowanie w niektórych modelach rynku energii elektrycznej (np. w „modelu kalifornijskim”).

SPIS TABLIC

Tablica 4.1.	Wartości parametrów opisujących jednostki wytwórcze przyjęte w zadaniu ERO na poziomie elektrowni.....	54
Tablica 4.2.	Błędy aproksymacji charakterystyk kosztów zmiennych bloków w %.....	68
Tablica 4.3.	Współczynniki wielomianów II-go stopnia aproksymujących charakterystyki kosztów zmiennych oraz błędy aproksymacji w %.....	69
Tablica 4.4.	Współczynniki funkcji aproksymujących (4.69) charakterystyki kosztów rozruchów oraz błędy aproksymacji w %.....	78
Tablica 4.5.	Sposób kodowania w algorytmie z binarną reprezentacją stanów pracy jednostek.....	80
Tablica 4.6.	Wartości zmiennych g_{om} i g_{zn} dla różnych harmonogramów pracy JW.....	98
Tablica 4.7.	Wartości dziesiętne łańcuchów binarnych B oraz odpowiadające im wartości zmiennych g_{om} i g_{zn}	99
Tablica 4.8.	Sposób kodowania w algorytmie z binarną reprezentacją momentów odstawień i załączeń..	99
Tablica 4.9.	Sposób kodowania w algorytmie z całkowitoliczbową reprezentacją momentów odstawień i załączeń.....	100
Tablica 4.10.	Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów ewolucyjnych.....	126
Tablica 4.11.	Najlepsze rozwiązanie zadania ERO-k dla elektrowni $P_{n\text{opt}}$, znalezione przez proponowane modele optymalizacyjne.....	128
Tablica 4.12.	Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów symulowanego wyżarzania.....	129
Tablica 4.13.	Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni z wykorzystaniem algorytmów SW+AE.....	131
Tablica 4.14.	Zestawienie najlepszych rezultatów obliczeń optymalizacyjnych dla zadania ERO-k na poziomie elektrowni w formie syntetycznej.....	141
Tablica 4.15.	Sposób kodowania w kompleksowym algorytmie ewolucyjnym stosowanym do ERO-z.....	143
Tablica 4.16.	Sposób kodowania w sekwencyjnym algorytmie ewolucyjnym stosowanym do ERO-z.....	152
Tablica 4.17.	Zestawienie rezultatów obliczeń optymalizacyjnych dla zadania ERO-z na poziomie elektrowni.....	156
Tablica 4.18.	Wpływ błędów parametrów modeli na wyniki obliczeń optymalizacyjnych.....	168
Tablica 4.19.	Zestawienie estymatorów parametrów rozkładu błędów funkcji kosztu.....	171
Tablica 4.20.	Zestawienie wyników testów statystycznych hipotez o zgodności rozkładu błędów funkcji kosztu z rozkładem normalnym.....	172
Tablica 4.21.	Zestawienie estymatorów parametrów rozkładu błędów określania obciążeń jednostek wytwórczych.....	175
Tablica 4.22.	Wpływ błędów poszczególnych parametrów modeli optymalizacyjnych na błędy funkcji kosztu.....	175
Tablica 4.23.	Wpływ błędów poszczególnych parametrów modeli optymalizacyjnych na błędy określania obciążeń JW.....	177

SPIS RYSUNKÓW

Rys. 4.1.	Przyjęty przebieg zapotrzebowania mocy.....	51
Rys. 4.2.	Schemat poglądowy procedur ERO-k.....	55
Rys. 4.3.	Charakterystyki kosztów zmiennych modelowanych bloków energetycznych.....	69
Rys. 4.4.	Struktura kosztów zmiennych bloku bez IOS (blok nr 1).....	70
Rys. 4.5.	Struktura kosztów zmiennych bloku z IOS (blok nr 10).....	70
Rys. 4.6.	Charakterystyki przyrostów względnych strumienia kosztów zmiennych modelowanych bloków energetycznych.....	71
Rys. 4.7.	Charakterystyki kosztów rozruchu modelowanych bloków energetycznych.....	78
Rys. 4.8.	Działanie operatora transpozycji na wybranym do transpozycji chromosomie ch	81
Rys. 4.9.	Działanie operatora mutacji MB2 na fragmencie ch_x chromosomu.....	84
Rys. 4.10.	Prawdopodobieństwa zmiany bitu z 0 na 1 (załączenia wybranej do mutacji jednostki; $i = 1, 2, \dots, 12$) $p_{oj}(i,t)$ w zależności od chwili $t = 1, 2, \dots, 24$, dla: $a_{oj1} = 0$, $a_{oj2} = 0,8$, zadanego przebiegu zapotrzebowania $P_c(t)$ oraz zadanych charakterystyk kosztów zmiennych jednostek $K_{zi}(P_{ni})$	88
Rys. 4.11.	Prawdopodobieństwa zmiany bitu z 1 na 0 (odstawienia wybranej do mutacji jednostki; $i = 1, 2, \dots, 12$) $p_{oj}(i,t)$ w zależności od chwili $t = 1, 2, \dots, 24$, dla: $a_{oj1} = 0$, $a_{oj2} = a_{oj3} = 0,9$, $t_{px} = 8$, zadanego przebiegu zapotrzebowania $P_c(t)$ i zadanych charakterystyk kosztów zmiennych $K_{zi}(P_{ni})$ oraz kosztów rozruchów jednostek $K_{ri}(t_{pi})$	89
Rys. 4.12.	Histogram obrazujący odsetek mutacji MBR, MB1, MB2 i MB3 w poszczególnych przedziałach procentowej zmiany wartości funkcji kosztu.....	91
Rys. 4.13.	Przedziały czasowe odstawień i załączeń jednostek dla przyjętego przebiegu zapotrzebowania $P_c(t)$	97
Rys. 4.14.	Wartości genów chromosomów potomnych względem genów rodzicielskich $c_x^u = 1$ i $c_x^v = 10$ po krzyżowaniu a) arytmetycznym całkowitoliczbowym i b) heurystycznym całkowitoliczbowym, w zależności od r_r	103
Rys. 4.15.	Przebieg dyskretnej funkcji $f_{\Delta}(l_{gen}, y)$ dla $n = 2$ i $y = 10$	104
Rys. 4.16.	Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmów ewolucyjnych – wersja kombinowana.....	106
Rys. 4.17.	Prawdopodobieństwo akceptacji punktów próbnych w zależności od ich jakości i zaawansowania procesu wyżarzania.....	110
Rys. 4.18.	Przykładowy przebieg procesu wyżarzania wg zmodyfikowanego schematu Aartsa: koszt punktów bieżących oraz temperatura na poszczególnych poziomach temperaturowych.....	114
Rys. 4.19.	Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmów symulowanego wyżarzania – wersja kombinowana.....	116
Rys. 4.20.	Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą algorytmu hybrydowego SW+AE – wersja kombinowana.....	120
Rys. 4.21.	Prawdopodobieństwa p przyjęcia przez zmienne w zadaniu ERO-k wartości z ich dziedzin po zastosowaniu wielokrotnej operacji krzyżowania arytmetycznego.....	123

Rys. 4.22.	Średnia wartość funkcji kosztu populacji (wykres górny) oraz koszt najlepszego osobnika (wykres dolny) w kolejnych generacjach AE: a) wariant AE1, b) wariant AE2, c) wariant AE3, d) wariant AE4.....	127
Rys. 4.23.	Najlepsze harmonogramy pracy jednostek wytwórczych.....	129
Rys. 4.24.	Średnia wartość funkcji kosztu punktów próbnych (wykres górny) oraz koszt najlepszego punktu próbnego (wykres dolny) na kolejnych poziomach temperaturowych SW: a) wariant SW1, b) wariant SW2, c) wariant SW3, d) wariant SW4.....	130
Rys. 4.25.	Średnia wartość funkcji kosztu populacji bieżącej (wykres górny) oraz koszt najlepszego punktu (wykres dolny) w kolejnych generacjach algorytmu SW+AE: a) wariant SW+AE1, b) wariant SW+AE2, c) wariant SW+AE3, d) wariant SW+AE4, e) wariant SW+AE5, f) wariant SW+AE6, g) wariant SW+AE7.....	133
Rys. 4.26.	Koszt punktu bieżącego w kolejnych iteracjach i algorytmu z twardą selekcją.....	134
Rys. 4.27.	Harmonogramy pracy jednostek wytwórczych otrzymane metodą charakterystyk czasów granicznych: a) z uwzględnieniem na etapie działania algorytmu warunków minimalnych czasów odstawień i pracy po uruchomieniu, b) bez uwzględnienia tych warunków.....	137
Rys. 4.28.	Koszty najlepszych rozwiązań w poszczególnych uruchomieniach testowanych algorytmów...	140
Rys. 4.29.	Przebieg funkcji $f_{\Delta}(l_{gen}, y)$ dla $n = 2$ i $y = 100$	145
Rys. 4.30.	Prawdopodobieństwo selekcji jednostek dla $N_r = 10$, w zależności od rangi g i parametru sterującego m_r	148
Rys. 4.31.	Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą kompleksowego algorytmu ewolucyjnego.....	151
Rys. 4.32.	Poglądowy schemat blokowy procedury ekonomicznego rozdziału obciążeń za pomocą sekwencyjnego algorytmu ewolucyjnego.....	155
Rys. 4.33.	Średnia wartość funkcji kosztu populacji (wykres górny) oraz koszt najlepszego osobnika (wykres dolny) w kolejnych generacjach algorytmu: a) KAE+SN1, b) KAE+SN2.....	157
Rys. 4.34.	Koszt (4.150) najlepszego osobnika w generacjach algorytmu SAE+SN2 dla kolejnych godzin t okresu optymalizacji T	157
Rys. 4.35.	Harmonogramy pracy jednostek wytwórczych otrzymane przy użyciu algorytmów: a) KAE+SN1, b) KAE+SN2, c) SAE+SN2.....	158
Rys. 4.36.	Histogram względnego wzrostu kosztów wytwarzania a) dla AE3, b) dla SAE.....	168
Rys. 4.37.	Empiryczna (narysowana grubszą linią) i aproksymowana dystrybuanta kosztów względnych $\delta_{F_{pop}}\%$ dla AE3.....	168
Rys. 4.38.	Histogramy błędów funkcji kosztu: a) dla AE3, b) dla KAE, c) dla SAE.....	172
Rys. 4.39.	Rodzina empirycznych dystrybuant błędów określania obciążeń poszczególnych jednostek: a) dla AE3, b) dla KAE, c) dla SAE.....	173
Rys. 4.40.	Zależności błędów funkcji kosztu od błędów poszczególnych parametrów modeli optymalizacyjnych: a) $\delta_{grKz}\%$, $\delta_{gr\bar{a}}\%$, b) $\delta_{grKr}\%$, c) $\bar{\delta}_{absPz}\%$, d) δ_P	176

LITERATURA

1. [Aar89] Aarts E., Korst J.: *Simulated Annealing and Boltzmann Machines*. John Wiley & Sons, Chichester 1989.
2. [Abi02] Abido M.: *Optimal Power Flow Using Particle Swarm Optimization*. *Electrical Power and Energy Systems*, 24, str. 563 – 571, 2002.
3. [AlA98] Al-Agtash S., Su Renjeng.: *Augmented Lagrangian Approach to Hydro-Thermal Scheduling*. *IEEE Trans. on Power Systems*, Vol. 13, No. 4, str. 1392 – 1400, 1998.
4. [Alg91] *Algorithmica. Special Issue: Simulated Annealing*, Vol. 6, No. 3, 1991.
5. [Ara01] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. WNT, Warszawa 2001.
6. [Ara02] Aravindhababu P., Nayar K.: *Economic Dispatch Based on Optimal Lambda Using Radial Basis Function Network*. *Electrical Power and Energy Systems*, 24, str. 551 – 556, 2002.
7. [Ayo71] Ayoub A. K., Patton A. D.: *Optimal Thermal Generating Unit Commitment*. *IEEE Trans. on Power Apparatus and Systems*, Vol. PAS-90, No. 3, str. 1752 – 1756, 1971.
8. [Bac97] Bäck T., Fogel D. B., Michalewicz Z. (edytorzy): *Handbook of Evolutionary Computation*. IOP Publishing Ltd and Oxford University Press, 1997.
9. [Bai97] Bai X., Shahidehpour S.: *Extended Neighborhood Search Algorithm for Constrained Unit Commitment*. *Electrical Power and Energy Systems*, Vol. 19, No. 5, str. 349 – 356, 1997.
10. [Bel67] Bellman R., Dreyfus S.: *Programowanie dynamiczne*. Państwowe Wydawnictwo Ekonomiczne, Warszawa 1967.
11. [Ber75] Bernatek M., Matla R.: *Metoda obliczania charakterystyk kotłów parowych do optymalizacji rozdziału obciążeń w elektrowniach*. Materiały konferencyjne: „Nowe Kierunki Optymalizacji w Energetyce”, str. 183 - 190, Poznań 1975.
12. [Ber77] Bernas S. i in.: *Optymalizacja rozdziału mocy czynnej z uwzględnieniem ograniczeń sieciowych*. *Archiwum Energetyki*, nr 2, str. 105 – 118, 1977.
13. [Ber86a] Bernas S.: *Systemy elektroenergetyczne*. WNT, Warszawa 1986.
14. [Ber86b] Bernas S., Mińczuk A., Zdun Z., Ziemiarek S.: *Laboratorium optymalizacji pracy systemu elektroenergetycznego*. Wydawnictwo Politechniki Warszawskiej, Warszawa 1986.
15. [Ber97] Berg P., Singer M.: *Język genów. Poznawanie zasad dziedziczenia*. Prószyński i S-ka, Warszawa 1997.
16. [Bob88] Bobrowski D., Maćkowiak-Lybacka K.: *Wybrane metody wnioskowania statystycznego*. Wydawnictwo Politechniki Poznańskiej, Poznań 1988.
17. [Boj99] Bojarski W.: *Wątpliwa poprawność stosowanych kryteriów optymalizacji w warunkach gospodarki rynkowej*. Materiały konferencyjne „Optymalizacja w Elektroenergetyce”, Jachranka k. Warszawy 1999.
18. [Bra98] Brandt S.: *Analiza danych*. PWN, Warszawa 1998.
19. [Brz02] Brzozowski W.: *EROKOMPL – kod źródłowy w Pascalu programu do obliczeń ERO metodą sekwencyjnego przeglądu zupełnego dla 3 bloków*. Politechnika Częstochowska, Częstochowa 2002.
20. [Brz73] Brzozowski W.: *Ekonomiczny poziom niezawodności urządzeń potrzeb własnych w elektrowniach blokowych w fazie projektowania*. Rozprawa doktorska, Politechnika Gliwicka, Gliwice 1973.
21. [Brz95a] Brzozowski W.: *Modelowanie i optymalizacja procesu eksploatacji elektrowni ciepłej*. Wydawnictwo Politechniki Częstochowskiej, Seria Monografie nr 35, Częstochowa 1995.
22. [Brz95b] Brzozowski W.: *Ekonomiczny rozdział obciążeń metodą programowania dynamicznego*. Materiały konferencyjne „Aktualne Problemy w Elektroenergetyce”, str. 23 – 30, Gdańsk, Jurata 1995.
23. [Brz97] Brzozowski W.: *Optymalizacja eksploatacji elektrowni z pomocą algorytmu genetycznego*. Materiały konferencyjne: „Algorytmy Ewolucyjne i Optymalizacja Globalna”, str. 25 – 32, Potok Złoty 1997. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1997.
24. [Car62] Carpentier J.: *Contribution a l'etude du dispatching economique*. *Bull. Soc. France Electriciens*, vol. 3, str. 431 – 447, 1962.
25. [Cha86] Charzyński W.: *Uniwersalny model wyznaczania strat energii podczas uruchamiania bloku*. *Energetyka*, nr 9, str. 345 – 348, 1986.
26. [Che98] Chen L. i in.: *Surrogate Constraint Method for Optimal Power Flow*. *IEEE Trans. on Power Systems*, Vol. 13, No. 3, str. 1084 – 1089, 1998.

27. [Cho95] Chong E., Żak S.: *An Introduction to Optimization*. John Wiley & Sons, New York 1995.
28. [Cis02] Ciszek K. i in.: *Elektrownia Opole na rynku dobowo – godzinowym – pierwsze doświadczenia*. Zeszyty Naukowe Politechniki Opolskiej. Seria Elektryka, z. 51, str. 127 – 133, Opole 2002.
29. [Coh83] Cohen A., Yoshimura M.: *A Branch-And-Bound Algorithm for Unit Commitment*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-102, No. 2, str. 444 – 450, 1983.
30. [Cos00] Da Costa G., Costa C., De Souza A.: *Comparative Studies of Optimization Methods for the Optimal Power Flow Problem*. Electric Power Systems Research, 56, str. 249 – 254, 2000.
31. [Cwy89] Cwynar L.: *Rozruch kotłów parowych*. WNT, Warszawa 1989.
32. [Dag97] Dagher S., Dębski B., Kowalski A.: *Nowoczesne technologie ochrony atmosfery*. Centrum Informatyki Energetyki. Zakład Energometrii, Warszawa 1997.
33. [Das94] Dasgupta D., McGregor D.: *Thermal Unit Commitment Using Genetic Algorithms*. IEE Proc.-Gener. Transm. Distrib., Vol. 141, No. 5, str. 459 – 465, 1994.
34. [Das99] Das Bhagwan D., Patvardhan C.: *Solution of Economic Load Dispatch Using Real Coded Hybrid Stochastic Search*. Electrical Power and Energy Systems, 21, str. 165 – 170, 1999.
35. [Dav87] Davis L. (edytor): *Genetic Algorithms and Simulated Annealing*. Morgan Kaufman Publishers, San Mateo 1987.
36. [Dem98] Demartini G. i in.: *Dual Programming Methods for Large-scale Thermal Generation Scheduling*. IEEE Trans. on Power Systems, Vol. 13, No. 3, str. 857 – 863, 1998.
37. [Dil78] Dillon T. i in.: *Integer Programming Approach to the Problem of Optimal Unit Commitment with Probabilistic Reserve Determination*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-97, No. 6, str. 2154 – 2166, 1978.
38. [Dob91] Dobrzańska I.: *Wymiar Hausdorffa jako narzędzie predykcji krokowej*. Badania Operacyjne i Decyzje, nr 2, str. 31 – 62, 1991.
39. [Dom79] Domański C.: *Statystyczne testy nieparametryczne*. Państwowe Wydawnictwo Ekonomiczne, Warszawa 1979.
40. [Dud00a] Dudek G.: *Algorytm genetyczny jako metoda optymalizacji doboru składu jednostek wytwórczych w systemie elektroenergetycznym*. Materiały konferencyjne: „Algorytmy Ewolucyjne i Optymalizacja Globalna”, str. 51 – 58, Łądek Zdrój 2000. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
41. [Dud00b] Dudek G.: *Sprawozdanie merytoryczne z projektu badawczego nr 8T10B01017 pt.: Krótkoterminowe prognozowanie obciążenia systemu elektroenergetycznego z zastosowaniem sztucznych sieci neuronowych o radialnych funkcjach bazowych*. Politechnika Częstochowska, Częstochowa 2000.
42. [Dud99a] Dudek G.: *Selekcja parametrów diagnostycznych metodą symulowanego wyżarzania*. Materiały konferencyjne: „Central European III Conference: Numerical Methods and Computer Systems in Automatic Control and Electrical Engineering”. Częstochowa/Poraj 1999. Wydawnictwo Politechniki Częstochowskiej, 1999.
43. [Dud99b] Dudek G.: *Zastosowanie algorytmu genetycznego do selekcji symptomów w badaniach diagnostycznych*. Materiały konferencyjne: „Algorytmy Ewolucyjne i Optymalizacja Globalna”, str. 99 – 106, Potok Złoty 1999. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1999.
44. [Duo99] Duo H. i in.: *A Solution for Unit Commitment Using Lagrangian Relaxation Combined with Evolutionary Programming*. Electric Power Systems Research, 51, str. 71 – 77, 1999.
45. [DzU93] *Rozporządzenie Rady Ministrów z dnia 27 grudnia 1993 r. w sprawie opłat za szczególne korzystanie z wód i urządzeń wodnych*. Dz.U.93.133.637 z dnia 30 grudnia 1993 r.
46. [DzU98a] *Rozporządzenie Ministra Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa z dnia 18 września 1998r. w sprawie szczegółowych zasad ustalania dopuszczalnych do wprowadzania do powietrza rodzajów i ilości substancji zanieczyszczających*. Dz.U.98.124.819 z dnia 30 września 1998r.
47. [DzU98b] *Rozporządzenie Rady Ministrów z dnia 22 grudnia 1998 r. w sprawie opłat za składowanie odpadów*. Dz.U.98.162.1128 z dnia 30 grudnia 1998 r.
48. [DzU98c] *Rozporządzenie Rady Ministrów z dnia 22 grudnia 1998 r. zmieniające rozporządzenie w sprawie opłat za wprowadzanie substancji zanieczyszczających do powietrza oraz za usuwanie drzew lub krzewów*. Dz.U.98.162.1129 z dnia 30 grudnia 1998 r.
49. [DzU98d] *Rozporządzenie Rady Ministrów z dnia 22 grudnia 1998 r. w sprawie kar pieniężnych za naruszanie wymagań ochrony środowiska oraz rejestru decyzji dotyczących tych kar*. Dz.U.98.162.1138 z dnia 30 grudnia 1998 r.
50. [DzU98e] *Rozporządzenie Ministra Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa z dnia 8 września 1998 r. w sprawie wprowadzania do powietrza substancji zanieczyszczających z procesów technologicznych i operacji technicznych*. Dz.U.98.121.793 z dnia 22 września 1998 r.

51. [DzU99a] *Rozporządzenie Rady Ministrów z dnia 21 grudnia 1999 r. zmieniające rozporządzenie w sprawie opłat za wprowadzanie substancji zanieczyszczających do powietrza oraz za usuwanie drzew lub krzewów.* Dz.U.99.110.1261 z dnia 30 grudnia 1999 r.
52. [DzU99b] *Rozporządzenie Rady Ministrów z dnia 21 grudnia 1999 r. zmieniające rozporządzenie w sprawie opłat za składowanie odpadów.* Dz.U.99.110.1263 z dnia 30 grudnia 1999 r.
53. [ElK94a] El-Keib A., Ma H., Hart J.: *Economic Dispatch in View of the Clean Air Act of 1990.* IEEE Trans. on Power Systems, Vol. 9, No. 2, str. 972 - 978, 1994.
54. [ElK94b] El-Keib A., Ma H., Hart J.: *Environmentally Constrained Economic Dispatch Using the LaGrangian Relaxation Method.* IEEE Trans. on Power Systems, Vol. 9, No. 4, str. 1723 - 1729, 1994.
55. [Emi99] *Emitor 1998. Emisja zanieczyszczeń środowiska w elektrowniach i elektrociepłowniach zawodowych.* Agencja Rynku Energii S.A. Warszawa 1999.
56. [Fan98] Fan Y-J. Zhang L.: *Real-Time Economic Dispatch with Line Flow and Emission Constraints Using Quadratic Programming.* IEEE Trans. on Power Systems, Vol. 13, No. 2, str. 320 – 325, 1998.
57. [Fin73] Findeisen W., Szymanowski J., Wierzbiński A.: *Metody obliczeniowe optymalizacji.* Wydawnictwo Politechniki Warszawskiej, Warszawa 1973.
58. [Fuk94] Fukuyama Y., Ueki Y.: *An Application of Neural Network to Dynamic Dispatch using Multi Processors.* IEEE Trans. on Power Systems, Vol. 9, No. 4, str. 1759 - 1765, 1994.
59. [Gal90] Galar R.: *Miękka selekcja w losowej adaptacji globalnej w R^n . Próba biocybernetycznego ujęcia rozwoju.* Wydawnictwo Politechniki Wrocławskiej. Wrocław 1990.
60. [Gen71] Gent M., Lamont J.: *Minimum-Emission Dispatch.* IEEE Trans. on Power Apparatus and Systems, Vol. PAS-90, No. 6, str. 2650 – 2660, 1971.
61. [Gen97] Gen M., Cheng R.: *Genetic Algorithms and Engineering Design.* John Wiley & Sons, New York 1997.
62. [Gła75] Gładys H., Czernienko A.: *Automatyzacja planowania pracy elektrowni w Państwowej Dyspozycji Mocy.* Energetyka, nr 12, str. 365 – 368, 1975.
63. [Gła80a] Gładys H.: *Komputery w kierowaniu pracą systemu elektroenergetycznego.* WNT, Warszawa 1980.
64. [Gła80b] Głanc Z.: *Probabilistyczny model dobowego planowania wytwarzania energii i systemie elektroenergetycznym.* Materiały konferencyjne: „Optymalizacja projektowania i eksploatacji systemów i urządzeń elektroenergetycznych”, t. 1, str. 236 – 243, Warszawa 1980.
65. [Gła80c] Głanc Z.: *Uwzględnienie awaryjności urządzeń przy dobowym planowaniu pracy elektrowni ciepłych.* Archiwum Energetyki, nr 3, str 171 – 178, 1980.
66. [Gła94] Gładys H.: *Rozdział obciążeń w warunkach rynku energii elektrycznej.* Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 211 – 223, Kazimierz Dolny 1994.
67. [Gła95] Gładys H.: *Kierunki optymalizacji planowania pracy KSE w warunkach hurtowego rynku energii elektrycznej.* W materiałach konferencyjnych „Optymalizacja w elektroenergetyce OPE’95”. Jachranka, 5 – 6 października 1995.
68. [Gła96] Gładys H. : *Jakie zasady prowadzenia ruchu w warunkach HREE.* Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 93 – 99, Kazimierz Dolny 1996.
69. [Gła97] Gładys H., Tabaka J.: *Kierunki optymalizacji ruchu i planowania pracy KSE w warunkach hurtowego rynku energii elektrycznej.* Materiały konferencyjne „Optymalizacja w Elektroenergetyce”, str. 9 – 16, Jachranka 1997.
70. [Gła99] Gładys H., Matla R.: *Praca elektrowni w systemie elektroenergetycznym.* WNT, Warszawa 1999.
71. [Gol95] Goldberg D.E.: *Algorytmy genetyczne i ich zastosowania.* WNT, Warszawa 1995.
72. [Gra00] Granelli G., Montagna M.: *Security-constrained Economic Dispatch Using Dual Quadratic Programming.* Electric Power Systems Research, 56, str. 71 – 80, 2000.
73. [Gre00] Greenberg H.: *Mathematical Programming Glossary.* <http://www-math.cudenver.edu/~hgreenbe/glossary/glossary.html>, 2000.
74. [Gro87] Gross G., Galiana F.: *Short-Term Load Forecasting.* Proceedings of the IEEE, Vol. 75, No. 12, str. 1558 – 1573, 1987.
75. [Gua95] Guan X., Liu W.-H., Papalexopoulos A.: *Application of A Fuzzy Set Method in An Optimal Power Flow.* Electric Power Systems Research, 34, str. 11 – 18, 1995.
76. [Guy71] Guy J. D.: *Security Constrained Unit Commitment.* IEEE Trans. on Power Apparatus and Systems, Vol. PAS-90, No. 3, str. 1385 – 1390, 1971.
77. [Hah31] Hahn G. R.: *Load Division by the Increment Method.* Power, June 1931.

78. [Han94] Hancock P.: *An Empirical Comparison of Selection Methods in Evolutionary Algorithms*. W [Fog94], str. 80 – 94.
79. [Han97] Hancock P.: *A Comparison of Selection Mechanisms*. W [Bac97], rozdz. C2.8.
80. [Hap71] Happ H. H.: *Large Scale Hydro-Thermal Unit Commitment-Method and Results*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-90, No. 3, str. 1373 – 1384, 1971.
81. [Hap77] Happ. H. H.: *Optimal Power Dispatch – A Comprehensive Survey*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-96, No. 3, str. 841 – 850, 1977.
82. [Her96] Herrera F., Verdegay J. L. (edytorzy): *Genetic Algorithms and Soft Computing*. Physica – Verlag, Heidelberg 1996.
83. [Hol75] Holland J.: *Adaptation in Natural and Artificial Systems*. University of Michigan 1975.
84. [Hot00] Hota P., Chakrabarti R., Chattopadhyay P.: *Economic Emission Load Dispatch Through an Interactive Fuzzy Satisfying Method*. Electric Power Systems Research, 54, str. 151 – 157, 2000.
85. [Hu94] Hu Y.-L., Wee W.: *A Hierarchical System for Economic Dispatch with Environmental Constraints*. IEEE Trans. on Power Systems, Vol. 9, No. 2, str. 1076 - 1082, 1994.
86. [Hua94] Huang G., Song K.: *A Simple Two Stage Optimization Algorithm for Power Economic Dispatch*. IEEE Trans. on Power Systems, Vol. 9, No. 4, str. 1818 - 1824, 1994.
87. [Hua98] Huang K-Y., Yang H-T., Huang C-L.: *A New Thermal Unit Commitment Approach Using Constraint Logic Programming*. IEEE Trans. on Power Systems, Vol. 13, No. 3, str. 936 – 945, 1998.
88. [Iri98] Irisarri G. i in.: *Economic Dispatch with Network and Ramping Constraints via Interior Point Methods*. IEEE Trans. on Power Systems, Vol. 13, No. 1, str. 236 – 242, 1998.
89. [Jan68] Janiczek R.: *Ekonomiczne aspekty pracy szczytowej konwencjonalnych elektrowni parowych*. Rozprawa doktorska, Politechnika Śląska, Gliwice 1968.
90. [Jan92] Janiczek R. S.: *Eksploracja elektrowni parowych*. WNT, Warszawa 1992.
91. [Jan96] Januszewska M., Rakowski J.: *Problemy rozdziału obciążeń w warunkach dochodzenia do rynku energii elektrycznej*. Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 101 – 107, Nałęczów 1996.
92. [Józ99] Józwiak A., Dudek G.: *Sprawozdanie merytoryczne z projektu badawczego nr 8T10B06014 pt.: Prognozowanie zapotrzebowania na energię elektryczną z zastosowaniem metod statystycznego rozpoznawania obrazów*. Instytut Biocybernetyki i Inżynierii Biomedycznej PAN, Warszawa 1999.
93. [Jud74] Juda J., Chróściel S.: *Ochrona powietrza atmosferycznego*. WNT, Warszawa 1974.
94. [Jur99] Jurek R.: *Matematyczny model systemowego, optymalizującego – bilansującego rynku energii elektrycznej (SOBREE)*. Materiały konferencyjne „Optymalizacja w Elektroenergetyce”, str. 19 – 32, Jachranka 1999.
95. [Jus99] Juste K. i in.: *An Evolutionary Programming Solution to the Unit Commitment Problem*. IEEE Trans. on Power Systems, Vol. 14, No. 4, str. 1452 - 1459, 1999.
96. [Kąd96] Kądzielawa A.: *Problem koordynacji rozdziału obciążeń i rynkowych zasad obrotu energią elektryczną*. Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 109 – 123, Nałęczów 1996.
97. [Kal00] Kaleta M., Toczyłowski E., Walczak A.: *Randomizacja algorytmu harmonogramowania pracy jednostek wytwórczych na rynku energii elektrycznej*. Materiały konferencyjne: „Algorytmy Ewolucyjne i Optymalizacja Globalna”, str. 99 – 106, Łądek Zdrój 2000. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
98. [Kar84] Karmarkar N.: *A New Polynomial-Time Algorithm Linear Programming*. Combinatorica, 4(4)b, str. 373 – 395, 1984.
99. [Kas97] Kasangaki V., Sendaula H., Biswas S.: *Stochastic Hopfield Artificial Neural Network for Unit Commitment and Economic Power Dispatch*. Electric Power Systems Research, 42, str. 215 – 223, 1997.
100. [Kaz96] Kazarlis S., Bakirtzis A., Petridis V.: *A Genetic Algorithm Solution to the Unit Commitment Problem*. IEEE Trans. on Power Systems, Vol. 11, No. 1, str. 83 - 89, 1996.
101. [Ker66] Kerr R. H. i in.: *Unit commitment*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-85, No. 5, str. 417 – 421, 1966.
102. [Ker75] Kerner A., Pietrachowicz J.: *Wyznaczanie rozplywu mocy metoda dynamicznego współczynnika akceleracji*. Energetyka, nr 7/10, str. 63 – 65, 1975.
103. [Kir83] Kirkpatrick S., Gelatt C. D., Vecchi M. P.: *Optimization by Simulated Annealing*. Science, Vol. 220, str. 671 – 680, No. 4598, 1983.
104. [Kłó60] Kłós A., Gładys H.: *Uwzględnienie strat sieciowych przy ekonomicznym rozdziale obciążeń*. Energetyka, nr 12, str. 373 – 378, 1962.

105. [Kł62a] Kłos A., Twardy L., Zieliński J. K.: *Zasady doboru optymalnej liczby kotłów i turbin do ruchu w dolinie obciążenia systemu elektroenergetycznego. Część 1.* Energetyka, nr 6, str. 165 – 168, 1962.
106. [Kł62b] Kłos A., Twardy L., Zieliński J. K.: *Zasady doboru optymalnej liczby kotłów i turbin do ruchu w dolinie obciążenia systemu elektroenergetycznego. Część 2.* Energetyka, nr 7, str. 198 – 203, 1962.
107. [Kł62c] Kłos A.: *Metoda obliczania współczynników strat sieciowych przy ekonomicznym rozdziale obciążeń.* Energetyka, nr 11, str. 338 – 341, 1962.
108. [Kł94] Kłos A.: *Rozdział obciążeń w warunkach rynku energii elektrycznej.* Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 201 – 210, Kazimierz Dolny 1994.
109. [Kob98] Kobus P., Pietrzykowski R., Zieliński W.: *Statystyka z pakietem STATISTICA.* Fundacja „Rozwój SGGW”, Warszawa 1998.
110. [Kon02] Kononowicz A., Witos T.: *Wpływ mechanizmów rynku bilansującego na eksploatację elektrowni na przykładzie Elektrowni Opole.* Zeszyty Naukowe Politechniki Opolskiej. Seria Elektryka, z. 51, str. 385 – 399, Opole 2002.
111. [Kos99] Kosman G., Rusin A.: *Model i algorytm optymalizacji charakterystyk rozruchowych turbin parowych.* Archiwum Energetyki, nr 3, 4, str. 3 – 17, 1999,
112. [Kos99] Koślarz P. i inni: *Optymalizacja Procesów Decyzyjnych.* Wydawnictwo Naukowe Wydziału Zarządzania Uniwersytetu Warszawskiego, Warszawa 1999.
113. [Kot00] Kotkowski A.: *Niektóre techniczne aspekty działania rynku energii elektrycznej.* Biuletyn Miesięczny PSE S.A., nr 4 (106), 2000.
114. [Kot71] Kotkowski A.: *Probabilistyczny model ekonomicznego rozdziału obciążeń.* Biuletyn Instytutu Energetyki (dodatek do miesięcznika Energetyka), nr 5/6, str. 37 – 40, 1971.
115. [Kot72] Kotkowski A.: *Probabilistyczny model ekonomicznego rozdziału obciążeń dla potrzeb planowania rozwoju systemu elektroenergetycznego.* Archiwum Energetyki, nr 1, str. 67 – 82, 1972.
116. [Kot82] Kotarski W.: *Propozycja równania uogólnionej charakterystyki zużycia strumienia energii chemicznej paliwa w kotle.* Gospodarka Paliwami i Energią, nr 5, str. 4 – 8, 1982.
117. [Kot95] Kothari D., Ahmad A.: *An Expert System Approach to the Unit Commitment Problem.* Energy Convers. Mgmt, Vol. 36, No. 4., str. 257 – 261, 1995.
118. [Koz94] Kożuchowski J.: *Sterowanie systemami elektroenergetycznymi.* PWN, Warszawa 1994.
119. [Kre96] Kremens Z., Sobierajski M.: *Analiza systemów elektroenergetycznych.* WNT, Warszawa 1996.
120. [Kuc97] Kucowski J., Laudyn D., Przekwas M.: *Energetyka a ochrona środowiska.* WNT, Warszawa 1997.
121. [Kul80] Kulczycki J., Kulczycka A.: *Ekonomiczny rozdział obciążeń metodą programowania dynamicznego.* Materiały konferencyjne: „Optymalizacja projektowania i eksploatacji systemów i urządzeń elektroenergetycznych”, t. 1, str. 111 – 116, Warszawa 1980.
122. [Łac91] Łączkowski R.: *Obliczanie wartości gwarantowanej jednostkowego zużycia ciepła dla turbozespołów parowych.* Energetyka, nr 3, str. 80 – 82, 1991.
123. [Lau82] Lauer G., Bertsekas D.: *Solution of Large-Scale Optimal Unit Commitment Problems.* IEEE Trans. on Power Apparatus and Systems, Vol. PAS-101, No. 1, str. 79 – 86, 1982.
124. [Lau97] Laudyn D., Pawlik M., Strzelczyk F.: *Elektrownie.* WNT, Warszawa 1997.
125. [Lau99] Laudyn D.: *Rachunek ekonomiczny w elektroenergetyce.* Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1999.
126. [Le83] Le K., Cooper B., Gibbons E.: *A Global Optimization Method for Scheduling Thermal Generation, Hydro Generation, and Economy Purchases.* IEEE Trans. on Power Apparatus and Systems, Vol. PAS-102, No. 7, str. 1986 – 1993, 1983.
127. [Lee02] Lee S., Kim Y.: *An Enhanced Lagrangian Neural Network for the ELD Problems with Piecewise Quadratic Cost Function and Nonlinear Constraints.* Electric Power Systems Research, 60, str. 167 – 177, 2002.
128. [Lee98] Lee K., Sode-Yome A., Park J.: *Adaptive Hopfield Neural Networks for Economic Load Dispatch.* IEEE Trans. on Power Systems, Vol. 13, No. 2, str. 519 – 526, 1998.
129. [Li98] Li F.: *A Comparison of Genetic Algorithms with Conventional Techniques on a Spectrum of Power Economic Dispatch Problems.* Expert Systems With Applications, 15, str. 133 – 142, 1998.
130. [Lia94a] Liang R., Hsu Y.: *Fuzzy Linear Programming: an Application to Hydroelectric Generation Scheduling.* IEE Proc.-Gener. Transm. Distrib., Vol. 141, No. 6, str. 568 – 574, 1994.
131. [Lia94b] Liang R., Hsu Y.: *Scheduling of Hydroelectric Generations Using Artificial Neural Networks.* IEE Proc.-Gener. Transm. Distrib., Vol. 141, No. 5, str. 452 – 458, 1994.

132. [Lon68] Longchamps J. i in.: *Nowa metoda techniczno-ekonomicznej kontroli pracy elektrowni (TKE)*. Biuletyn "Energopomiaru" (dodatek do miesięcznika Energetyka). Nr 3 (61), 1968.
133. [Lon74] Longchamps J., Sobiś Z.: *Analiza danych uzyskanych metodą TKE – techniczno-ekonomicznej kontroli pracy elektrowni do 1972 r.* Biuletyn "Energopomiaru" (dodatek do miesięcznika Energetyka). Nr 5/6, str. 45 - 48, 1974.
134. [Lon84] Longchamps J., Sobiś Z.: *Praktyczna metoda aktualizacji charakterystyk bloków energetycznych do ekonomicznego rozdziału obciążeń w systemie elektroenergetycznym*. Energetyka, nr 10, str. 437 – 440, 1984.
135. [Low66] Lowery P. G.: *Generating Unit Commitment by Dynamic Programming*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-85, No. 5, str. 422 – 426, 1966.
136. [Luh98] Luh P., Zhang D., Tomastik R.: *An Algorithm for Solving the Dual Problem of Hydrothermal Scheduling*. IEEE Trans. on Power Systems, Vol. 13, No. 2, str. 593 – 600, 1998.
137. [Łyp99] Łyp J.: *Metodyka analizy i prognozy obciążeń elektroenergetycznych systemów lokalnych*. Rozprawa doktorska, Politechnika Częstochowska, Częstochowa 1999.
138. [Maj02] Majchrzak H. i in.: *Techniczno – ekonomiczne efekty wdrożenia eksploatacyjnego systemu do bieżącego wyznaczania strat i kosztów rozruchowych bloków Elektrowni Opole S.A.* Zeszyty Naukowe Politechniki Opolskiej. Seria Elektryka, z. 51, str. 487 – 495, Opole 2002.
139. [Man98] Mantawy A., Abdel-Magid Y., Selim S.: *A Simulated Annealing Algorithm for Unit Commitment*. IEEE Trans. On Power Systems, Vol. 13, No. 1, str. 197-204, 1998.
140. [Man99a] Mantawy A., Abdel-Magid Y., Selim S.: *A New Genetic-Based Tabu Search Algorithm for Unit Commitment Problem*. Electric Power Systems Research, 49, str. 71 – 78, 1999.
141. [Man99b] Mantawy A., Abdel-Magid Y., Selim S.: *Integrating Genetic Algorithms, Tabu Search, And Simulated Annealing for the Unit Commitment Problem*. IEEE Trans. on Power Systems, Vol. 14, No. 3, str. 829 - 836, 1999.
142. [Mat01] *Matlab Statistics Toolbox. User's Guide v. 3*. MathWorks 2001.
143. [Maz97] Mazurkiewicz E., Urbaniak Z.: *System regulatora grupowego w Elektrowni Belchatów*. Opracowanie wewnętrzne Elektrowni Belchatów, 1997.
144. [Mba95] Mbamalu G., El-Hawary F., El-Hawary M.: *Effects of Load Modeling on Minimum Loss, Minimum Emission, and Multiple-objective Optimal Hydrothermal Power Flow*. Electric Power Systems Research, 34, str. 97 – 108, 1995.
145. [Mer83] Merlin A., Sandrin P.: *A New Method for Unit Commitment at Electricite de France*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-102, No. 5, str. 1218 – 1225, 1983.
146. [Met53] Metropolis N., Rosenbluth, A. W., Rosenbluth, M. N., Teller, A. H., Teller, E.: *Equation of State Calculations by Fast Computing Machines*. J. Chem. Phys., 21, str. 1087-1091, 1953.
147. [Mic96a] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. WNT, Warszawa 1996.
148. [Mic96b] Michalewicz Z. i in.: *Evolutionary Algorithms for Constrained Engineering Problems*. Computers ind. Engng, Vol. 30, No. 4., str. 851 – 870, 1996.
149. [Mic97] Michalewicz Z.: *Repair Algorithms*. W [Bac97], rozdz. C5.4.
150. [Mie00] Mielczarski W.: *Rynki energii elektrycznej. Wybrane aspekty techniczne i ekonomiczne*. Agencja Rynku Energii S.A., Energoprojekt-Consulting S.A., Warszawa 2000.
151. [Mie98] Mielczarski W. (edytor): *Fuzzy Logic Techniques in Power Systems*. Phisica-Verlag, Heidelberg, New York 1998.
152. [Mir98] Miranda V., Srinivasan D., Proenca L.: *Evolutionary Computation in Power Systems*. Electrical Power and Energy Systems, Vol. 20, No. 2, str. 89 – 98, 1998.
153. [Mis94] Misra N., Baghzouz Y.: *Implementation of the Unit Commitment Problem on Supercomputers*. IEEE Trans. on Power Systems, Vol. 9, No. 1, str. 305 - 310, 1994.
154. [Mok88] Mokhtari S., Singh J., Wollenberg B.: *A Unit Commitment Expert System*. IEEE Trans. on Power Systems, Vol. 3, No. 1, str. 272 – 276, 1988.
155. [Mom94] Momoh J. i in.: *The Quadratic Interior Point Method Solving Power System Optimization Problems*. IEEE Trans. on Power Systems, Vol. 9, No. 3, str. 1327 – 1336, 1994.
156. [Mom99a] Momoh J., El-Hawary M., Adapa R.: *A Review of Selected Optimal Power Flow Literature to 1993. Part I: NonLinear and Quadratic Programming Approaches*. IEEE Trans. on Power Systems, Vol. 14, No. 1, str. 96 – 104, 1999.

157. [Mom99b] Momoh J., El-Hawary M., Adapa R.: *A Review of Selected Optimal Power Flow Literature to 1993. Part II: Newton, Linear Programming and Interior Point Methods*. IEEE Trans. on Power Systems, Vol. 14, No. 1, str. 105 - 111, 1999.
158. [MOŚ96] Materiały informacyjno – instruktażowe Ministerstwa Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa: *Wskaźniki emisji substancji zanieczyszczających wprowadzanych do powietrza z procesów energetycznego spalania paliw*. Warszawa 1996.
159. [Nan94] Nanda J., Hari L., Kothari M.: *Economic Emission Load Dispatch with Line Flow Constraints Using a Classical Technique*. IEE Proc.-Gener. Transm. Distrib., Vol. 141, No. 1, str. 1 – 10, 1994.
160. [Nay00] Nayak R., Sharma J.: *A Hybrid Neural Network and Simulated Annealing Approach to the Unit Commitment Problem*. Computers and Electrical Engineering, 26, str. 461 – 477, 2000.
161. [Neh74] Nehrebecki L.: *Elektrownie ciepłe*. WNT, Warszawa 1974.
162. [Olk00] Olkusi T.: *Elektroenergetyka polska a normy emisji*. Polityka energetyczna, t. 1, zeszyt 1, str. 101 – 125, 2000.
163. [Ols76] Olszewski A., Szafran R.: *Zastosowanie metody aproksymacji statystycznej do wyznaczania charakterystyk energetycznych kotłów i turbozespołów*. Archiwum Energetyki, nr 3, str. 129 – 135, 1976.
164. [Ong99] Ongsakul W.: *Real-time Economic Dispatch Using Merit Order Loading for Linear Decreasing and Staircase Incremental Cost Function*. Electric Power Systems Research, 51, str. 167 – 173, 1999.
165. [Ore97] Orero S., Irving M.: *A Combination of the Genetic Algorithm and Lagrangian Relaxation Decomposition for the Generation Unit Commitment Problem*. Electric Power Systems Research, 43, str. 149 – 156, 1997.
166. [Orv94] Orvosh D., Davis L.: *Using a Genetic Algorithm to Optimize Problems with Feasibility Constraints*. In Fogel D. (editor): „Proceedings of the First IEEE Conference on Evolutionary Computation”. IEEE Press, Orlando FL 1994.
167. [Oso96] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa 1996.
168. [Pad00] Padhy N.: *Unit Commitment Using Hybrid Models: A Comparative Study for Dynamic Programming, Expert System, Fuzzy System and Genetic Algorithms*. Electrical Power and Energy Systems, 23, str. 827 – 836, 2000.
169. [Pad97] Padhy N., Paranjothi S., Ramachandran V.: *A Hybrid Fuzzy Neural Network – Expert System for a Short Term Unit Commitment Problem*. Microelectron. Reliab., Vol. 37, No. 5, str. 733 – 737, 1997.
170. [Pan76] Pang C. K., Chen H. C.: *Optimal Short-Term Thermal Unit Commitment*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-95, No. 4, str. 1336 – 1342, 1976.
171. [Pan81] Pang C. K., Sheble G. B., Albuyeh F.: *Evaluation of Dynamic Programming based Methods and Multiple Area Representation for Thermal Unit Commitments*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-100, No. 3, str. 1212 – 1218, 1981.
172. [Pao89] Pao Y-H.: *Adaptive Pattern Recognition and Neural Networks*. Addison-Wesley Publishing Co., Reading, MA, 1989.
173. [Paw98] Pawłowski Z., Gieras M., Laudyn D. (red.): *Elektrownia Bełchatów 1973 – 1998*. Wydawnictwo i Zakład Poligrafii Instytutu Technologii Eksploatacji, Elektrownia Bełchatów 1998.
174. [PN-72] PN-72/M-34128: *Kotły parowe. Wymagania i badania odbiorcze*.
175. [Poł96] Połacki Z.: *Ekonomiczny rozdział obciążeń a rynek energii elektrycznej*. Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 125 – 135, Nałęczów 1996.
176. [Poł99] Połacki Z.: *Praca elektrowni w systemie elektroenergetycznym w warunkach rynku energii elektrycznej*. Materiały konferencyjne „Rynek Energii Elektrycznej”, str. 79 – 86, Kazimierz Dolny 1999.
177. [Pop99] Popczyk J.: *Rozwój rynku hurtowego energii elektrycznej w Polsce*. Materiały konferencyjne „Rynek Energii Elektrycznej”, Kazimierz Dolny 1999.
178. [Por00] Porała J.: *Instalacje odsiarczania spalin w Elektrowni „Rybnik” S.A.* Energetyka, nr 11, str. 530 – 534, 2000.
179. [Por96] *Poradnik inżyniera elektryka*. Tom 3. WNT, Warszawa 1996.
180. [Prz70] Przyłuski A., Mikołajczyk S.: *Uwzględnienie strat sieciowych przy ekonomicznym rozdziale obciążeń w krajowym systemie elektroenergetycznym*. Energetyka, nr 5/6, str. 42 – 46, 1970.
181. [Ram94] Ramanathan R.: *Emission Constrained Economic Dispatch*. IEEE Trans. on Power Systems, Vol. 9, No. 4, str. 1994 – 2000, 1994.
182. [Res96] Research Specific Committee.: *Neural Networks, Fuzzy Logic and Genetic Algorithms in the Electricity Supply Industry*. UNIPED, Paris 1996.
183. [Roa00] Roa-Sepulveda C., Herrera M.: *A Solution of the Economic Dispatch Problem Using Decision Trees*. Electric Power Systems Research, 56, str. 255 – 259, 2000.

184. [Rom91] Romeo F., Sangiovanni-Vincentelli A.: *A Theoretical Framework for Simulated Annealing*. W [Alg91], str. 302 – 345.
185. [Rut97] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, Warszawa 1997.
186. [Ruz98] Ruzic S., Rajakovic N.: *Optimal Distance Method for Lagrangian Multipliers Updating in Short-Term Hydro-Thermal Coordination*. IEEE Trans. on Power Systems, Vol. 13, No. 4, str. 1439 – 1444, 1998.
187. [Rze99] Rzewuski M., Arabas J., Domański P.: *Rozwiązanie problemu ekonomicznego rozdziału obciążeń przy wykorzystaniu wybranych algorytmów optymalizacji globalnej*. Materiały konferencyjne: „Algorytmy Ewolucyjne i Optymalizacja Globalna”, str. 275 – 282, Potok Złoty 1999. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1999.
188. [Sar96] Sarfi R., Salama M., Chikhani A.: *Applications of Fuzzy Sets Theory in Power Systems Planning and Operation: A Critical Review to Assist in Implementation*. Electric Power Systems Research, 39, str. 89 – 101, 1996.
189. [Sch01] Schaefer R.: *Zagadnienia zbieżności algorytmów genetycznych*. Materiały konferencyjne „Metody i Systemy Komputerowe w Badaniach Naukowych i Projektowaniu Inżynierskim”, AGH, Kraków 2001.
189. [Sen98] Sen S., Kothari D.: *Optimal Thermal Generating Unit Commitment: A Review*. Electrical Power and Energy Systems, Vol. 20, No. 7, str. 443 – 451, 1998.
190. [She94a] Sheble G. B., Fahd G. N.: *Unit Commitment Literature Synopsis*. IEEE Trans. on Power Systems, Vol. 9, No. 1, str. 128 - 136, 1994.
191. [She94b] Sheble G., Maifeld T.: *Unit Commitment by Genetic Algorithm and Expert System*. Electric Power Systems Research, 30, str. 115 – 121, 1994.
192. [She96] Sheble G. i in.: *Unit Commitment by Genetic Algorithm with Penalty Methods and a Comparison of Lagrangian Search and Genetic Algorithm – Economic Dispatch Example*. Electrical Power and Energy Systems, Vol. 18, No. 6, str. 339 – 346, 1996.
193. [Shi01] Shi L., Xu G.: *Self-Adaptive Evolutionary Programming and Its Applications to Multi-Objective Optimal Operation of Power Systems*. Electric Power Systems Research, 57, str. 181 – 187, 2001.
194. [Sob84] Sobierajski M.: *Rozpływ mocy i rozdział obciążeń w warunkach losowych*. Prace Naukowe Instytutu Energoelektryki Politechniki Wrocławskiej, nr 57. Seria: Monografie, nr 12, Wrocław 1984.
195. [Son98] Song T., Chou C., Stonham T.: *Combined Heat and Power Economic Dispatch by Improved Ant Colony Search Algorithm*. Electric Power Systems Research, 52, str. 115 – 121, 1999.
196. [Sta30] Stahl E. C. M.: *Load Division in Interconnections*. Electrical World, March 1, 1930.
197. [Ste34] Steinberg M. J., Smith T. H.: *The Theory of Incremental Rates*. Part I, Electrical Engineering, March 1934, Part II, Electrical Engineering, April 1934.
198. [Su91] Su C., Hsu Y.: *Fuzzy Dynamic Programming: An Application to Unit Commitment*. IEEE Trans. on Power Systems, Vol. 6, No. 3, str. 1231 – 1237, 1991.
199. [Sys93] Sysło M., Deo N., Kowalik J.: *Algorytmy optymalizacji dyskretnej z programami w języku Pascal*. PWN, Warszawa 1993.
200. [Sza86] Safran R.: *Metodologia wyznaczania charakterystyk energetycznych urządzeń podstawowych w elektrowniach ciepłych*. Prace Naukowe Instytutu Energoelektryki Politechniki Wrocławskiej. Seria monografie. Wydawnictwo Politechniki Wrocławskiej, Wrocław 1986.
201. [Szo74] Szostek T.: *Metoda optymalizacji poziomów napięć i rozpływów mocy biernej w systemie elektroenergetycznym*. Biuletyn "Energopomiaru" (dodatek do miesięcznika Energetyka). Nr 4 (98), str. 25 – 29, 1974.
202. [Szo76] Szostek T.: *Metoda optymalizacji rozdziału obciążeń mocy czynnej i biernej w systemie elektroenergetycznym*. Prace Naukowe Instytutu Energoelektryki Politechniki Wrocławskiej, nr 34. Seria: Konferencje, nr 3, str. 53 – 62, Wrocław 1976.
203. [Tak00] Takriti S., Birge J.: *Using Integer Programming to Refine Lagrangian-Based Unit Commitment Solution*. IEEE Trans. on Power Systems, Vol. 15, No. 1, str. 151 - 155, 2000.
204. [Tal94a] Talaq J. H., El-Hawary F., El-Hawary M.E.: *Minimum Emissions Power Flow*. IEEE Trans. on Power Systems, Vol. 9, No. 1, str. 429 - 436, 1994.
205. [Tal94b] Talaq J. H., El-Hawary F., El-Hawary M.E.: *A Summary of Environmental/Economic Dispatch Algorithms*. IEEE Trans. on Power Systems, Vol. 9, No. 3, str. 1508 - 1516, 1994.
206. [Toc99] Toczyłowski E. i in. : *Analiza porównawcza zdecentralizowanych i scentralizowanych struktur rynków energii elektrycznej*. Materiały konferencyjne „Rynek Energii Elektrycznej”, Kazimierz Dolny 1999.

207. [Tor62] Toroń M.: *Metoda dobierania optymalnego zestawu urządzeń wytwórczych w systemach energetycznych*. Rozprawa doktorska, Wrocław 1962.
208. [Tor66] Toroń M., Oziemblewski K.: *Ustalanie charakterystyk korzyści z odstawiania lub uruchamiania jednostek prądowców w systemie elektroenergetycznym*. Energetyka, nr 12, str. 357 – 359, 1966.
209. [Tra98] Travers D., Kaye J.: *Dynamic Dispatch by Constructive Dynamic Programming*. IEEE Trans. on Power Systems, Vol. 13, No. 1, str. 72 – 78, 1998.
210. [Vad90] Praca zbiorowa: *Vademecum Elektrowni Bełchatów 4320MW*. Instytut Wydawniczy Związków Zawodowych, Warszawa 1990.
211. [Wai81] Waight J. G., Albuyeh F., Bose A.: *Scheduling of Generation and Reserve Margin Using Dynamic and Linear Programming*. IEEE Trans. on Power Apparatus and Systems, Vol. PAS-100, No. 5, str. 2226 – 2230, 1981.
212. [Wal99] Walczak A. i in.: *Wspomaganie decyzji dobrego planowania pracy jednostek wytwórczych na rynku energii elektrycznej*. Materiały konferencyjne „Optymalizacja w Elektroenergetyce”, str. 33 – 42, Jachranka 1999.
213. [Wan94] Wang C., Shahidehpour S.: *Ramp-Rate Limits in Unit Commitment and Economic Dispatch Incorporating Rotor Fatigue Effect*. IEEE Trans. on Power Systems, Vol. 9, No. 3, str. 1539 – 1545, 1994.
214. [Wei98] Wei H. i in.: *An Interior Point Nonlinear Programming for Optimal Power Flow Problems with A Novel Data Structure*. IEEE Trans. on Power Systems, Vol. 13, No. 3, str. 870 – 877, 1998.
215. [Wiś91] Wiśniewski W.: *Diagnostyka techniczna wytwórczych urządzeń energetycznych w elektrowniach*. PWN, Warszawa 1991.
216. [Won00] Wong M., Chung T., Wong Y.: *An Evolving Neural Network Approach in Unit Commitment Solution*. Microprocessors and Microsystems, 24, str. 251 – 262, 2000.
217. [Won98a] Wong K., Yuryevich J.: *Evolutionary-Programming-Based Algorithm for Environmentally-Constrained Economic Dispatch*. IEEE Trans. on Power Systems, Vol. 13, No. 2, str. 301 – 306, 1998.
218. [Won98b] Wong S.: *An Enhanced Simulated Annealing Approach to Unit Commitment*. Electrical Power and Energy Systems, Vol. 20, No. 5, str. 359 – 368, 1998.
219. [Woo96] Wood A., Wollenberg B.: *Power Generation, Operation, and Control*. John Wiley & Sons, New York, 1996.
220. [Wor85] Working Group 03: *Operational Planning Function – Short Term Scheduling – Present Practices and Trends*. CIGRE Study Committee 39 Meeting, Canada 1985.
221. [www1] Strona internetowa Elektrowni Bełchatów – <http://www.elb.pl>
222. [www2] Strona internetowa firmy „ABB” – <http://www.abb.com>
223. [www3] Strona internetowa z opisem pakietu GE-PSLF – http://www.gepower.com/dhtml/energyconsulting/en_us/software/pslf
224. [www4] Strona internetowa z opisem pakietu NETOMAC – <http://www.ev.siemens.de/ev/en/pages/netomac.htm>
225. [www5] *Ant Colony Optimisation Home Page* – <http://iridia.ulb.ac.be/~mdorigo/ACO/ACO.html>
226. [Yal01] Yalcinoz T., Cory B., Short M.: *Hopfield Neural Network Approaches to Economic Dispatch Problem*. Electrical Power and Energy Systems, 23, str. 435 – 442, 2001.
227. [Yal98] Yalcinoz T., Short M.: *Neural Networks Approach for Solving Economic Dispatch Problem with Transmission Capacity Constraints*. IEEE Trans. on Power Systems, Vol. 13, No. 2, str. 307 – 313, 1998.
228. [Yur99] Yuryevich J., Wong K.: *Evolutionary Programming Based Optimal Power Flow Algorithm*. IEEE Trans. on Power Systems, Vol. 14, No. 4, str. 1245 – 1250, 1999.
229. [Zdu00] Zdun Z., Księżyk K., Zdun T.: *Instrukcja użytkownika programu PLANS_PCZ v.d/2000L*.
230. [Zdu79] Zdun Z.: *Algorytmy podstawowych obliczeń systemów elektroenergetycznych*. Wydawnictwo Politechniki Warszawskiej, Warszawa 1979.
231. [Zhu95] Zhu R., Fu C., Rahman S.: *Network programming Technique for Unit Commitment*. Electrical Power and Energy Systems, Vol. 17, No. 2, str. 123 – 127, 1995.
232. [Zie68] Zieliński J. K.: *Ekonomiczny rozdział obciążeń z uwzględnieniem odstawień jednostek blokowych*. Biuletyn Instytutu Energetyki (dodatek do miesięcznika Energetyka). Nr 1/2, str. 1 – 7, 1968.
233. [Zie98] Zieliński J.: *Artificial Intelligence Contemporary Applications in Power Systems*. Materiały konferencyjne IV Sympozjum „Metody Matematyczne w Elektroenergetyce”, Zakopane 1998.
234. [Żur96] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe*. PWN, Warszawa 1996.